

**SVEUČILIŠTE U ZAGREBU**  
**FAKULTET PROMETNIH ZNANOSTI**

**Marin Širol**

**SUSTAV PODRŠKE PRI ODLUČIVANJU U PROCESU  
REGULACIJE ŽELJEZNIČKOG PROMETA  
TEMELJEN NA NEIZRAZITOJ LOGICI**

**DIPLOMSKI RAD**

**Zagreb, 2018.**

Sveučilište u Zagrebu  
Fakultet prometnih znanosti

**DIPLOMSKI RAD**

**SUSTAV PODRŠKE PRI ODLUČIVANJU U PROCESU  
REGULACIJE ŽELJEZNIČKOG PROMETA  
TEMELJEN NA NEIZRAZITOJ LOGICI**

**DECISION SUPPORT SYSTEM FOR RAILWAY  
TRAFFIC CONTROL BASED ON FUZZY LOGIC**

Mentor: doc. dr. sc. Hrvoje Haramina

Student: Marin Širol  
JMBAG:0135233308

Zagreb, rujan 2018.

# SUSTAV PODRŠKE PRI ODLUČIVANJU U PROCESU REGULACIJE ŽELJEZNIČKOG PROMETA TEMELJEN NA NEIZRAZITOJ LOGICI

## SAŽETAK

Razvojem umjetne inteligencije dolazi do sve veće mogućnosti njene primjene u različitim poslovima, u kojima može zamijeniti ljudsko djelovanje. Neizrazita logika jedna je od grana umjetne inteligencije te se može primjenjivati za izradu ekspertnih sustava koji pružaju podršku pri upravljanju prometom. Potreba za primjenom takvog sustava u željezničkom prometu javlja se kod centraliziranog upravljanja, gdje glavnu ulogu u upravljanju prometom ima dispečer, koji ima značajna radna opterećenja. U ovom radu predstavljen je novi model sustava podrške pri odlučivanju u procesu regulacije željezničkog prometa. Novi model sustava izrađen je u programu Matlab. Izrađeni model sustava rješava problem određivanja prioriteta vlakovima koji istovremeno žele pristupiti istim infrastrukturnim elementima. Primjena navedenog sustava podrške može dovesti do značajnijeg smanjenja radnog opterećenja dispečera. Analiza utjecaja rješenja prikazanog modela sustava podrške na odvijanje željezničkog prometa izvršena je u programu OpenTrack.

**KLJUČNE RIJEČI:** umjetna inteligencija; neizrazita logika; sustav podrške pri odlučivanju

## SUMMARY

With the development of artificial intelligence there is an increasing opportunity of its application in the various jobs in which it can replace human operation. Fuzzy logic is one of the branches of artificial intelligence and it can be used to create expert systems that provide traffic management support. The need for application of such system in railway traffic occurs in centralized traffic control, where a dispatcher, which has significant workloads, has the main role in traffic management. A new model of decision support system for railway traffic is presented in this paper. The new model of the system was created in Matlab. Made model solves problem of prioritizing trains that simultaneously want to access the same infrastructure elements. Applying this support system can lead to a significant reduction of dispatcher's workload. The impact analysis of the solution of system model on railway traffic was performed in OpenTrack.

**KEY WORDS:** artificial intelligence, fuzzy logic, decision support system

# SADRŽAJ:

1. UVOD.....	1
2. SUSTAVI NEIZRAZITOG ZAKLJUČIVANJA .....	3
2.1. Razvoj i vrste sustava neizrazitog zaključivanja .....	3
2.2. Proces zaključivanja u neizrazitom sustavu .....	6
2.2.1. Pridruživanje vrijednosti funkcije pripadnosti.....	7
2.2.2. Interferencija .....	11
2.2.3. Agregacija .....	15
2.2.4. Računanje pripadne čvrste vrijednosti .....	15
2.2.5. Primjer procesa zaključivanja u neizrazitom sustavu .....	15
2.3. Prednosti i nedostaci sustava neizrazitog zaključivanja te mogućnosti njihove primjene .....	17
3. PRIMJENA INTELIGENTNIH TRANSPORTNIH SUSTAVA U PROCESU UPRAVLJANJA ŽELJEZNIČKIM PROMETOM.....	19
3.1. Centralizirano upravljanje željezničkim prometom.....	19
3.2. Automatsko postavljanje putova vožnje.....	26
4. IZRADA NOVOG MODELA SUSTAVA PODRŠKE PRI REGULACIJI ŽELJEZNIČKOG PROMETA TEMELJENOG NA NEIZRAZITOJ LOGICI .....	31
4.1. Definiranje ulaznih i izlaznih varijabli sustava .....	33
4.1.1. Razlika u rangi vlaka.....	35
4.1.2. Kašnjenje vlaka koje utječe na stabilnost drugih vlakova.....	36
4.1.3. Popunjenost putničkog vlaka .....	37
4.1.4. Gubici vremena i energije zbog zaustavljanja vlaka radi davanja prednosti drugom vlaku.....	38
4.1.5. Broj bodova.....	39
4.2. Izrada i pregled pravila sustava podrške pri regulaciji željezničkog prometa.....	40

4.3. Primjer korištenja novog modela sustava podrške pri regulaciji željezničkog prometa.....	43
5. SIMULACIJSKA ANALIZA RADA SUSTAVA PODRŠKE PRI REGULACIJI ŽELJEZNIČKOG PROMETA.....	45
5.1. Prvi primjer analize rada sustava podrške pri regulaciji željezničkog prometa .....	47
5.2. Drugi primjer analize rada sustava podrške pri regulaciji željezničkog prometa .....	49
6. ZAKLJUČAK .....	51
7. LITERATURA.....	52
POPIS SLIKA .....	54
POPIS TABLICA.....	55
PRILOZI.....	56

# 1. UVOD

Uspješna regulacija željezničkog prometa od ključne je važnosti za sigurno i nesmetano odvijanje željezničkog prometa te optimalno iskorištenje kapaciteta željezničke infrastrukture. Tijekom godina principi regulacije željezničkog prometa značajno su se mijenjali s ciljem povećanja efikasnosti odvijanja prometa i smanjenja troškova. Upravo radi navedenih ciljeva razvija se sustav centraliziranog upravljanja željezničkim prometom, u kojem glavnu ulogu ima dispečer koji regulira promet na većem dijelu mreže željezničkih pruga. Dispečerov posao zahtijeva rješavanje vrlo kompleksnih problema, što uzrokuje stvaranje velikog radnog opterećenja. Zbog toga dolazi do potrebe razvoja sustava koji bi dispečeru mogli pomoći prilikom rješavanja problema koji se pred njega stavljaju.

Pojavom računala i računalne tehnike dolazi do razvoja umjetne inteligencije, koja se može primjenjivati u različitim područjima ljudskog djelovanja. Tako dolazi do razvoja inteligentnih transportnih sustava koji predstavljaju ekspertne sustave temeljene na tehnikama umjetne inteligencije, kao što su neizrazita logika, genski algoritmi itd. Njihova svrha je zamjena ljudi u izvršavanju određenih zadataka vezanih uz promet. Takvi sustavi mogu znatno doprinijeti smanjenju radnog opterećenja na određenim radnim mjestima, a najviše su primjenjivi u pružanju pomoći ili zamjenjivanju ljudi u procesu upravljanja prometom.

Razvoj inteligentnih transportnih sustava, kao i neizrazite logike, dovodi do mogućnosti izrade sustava čija je svrha pružanje podrške dispečeru prilikom rješavanja problema i donošenja odluka u procesu reguliranja željezničkog prometa. Takav sustav može dovesti do značajnog smanjenja radnog opterećenja dispečera te do povećanja učinkovitosti upravljanja željezničkim prometom. Navedeni sustavi podrške pri odlučivanju mogu biti temeljeni na principu automatskog postavljanja putova vožnje, gdje rješavaju problem davanja prioriteta kada vlakovi istovremeno žele koristiti iste elemente željezničke infrastrukture.

Cilj diplomskog rada je izraditi model sustava podrške dispečeru prilikom odlučivanja u procesu reguliranja željezničkog prometa temeljenog na neizrazitoj logici. U okviru toga potrebno je odrediti kriterije za odlučivanje pri dodjeli prioriteta kod postavljanja putova vožnje za vlakove koji istovremeno žele koristiti iste elemente željezničke infrastrukture, u svrhu povećanja učinkovitosti željezničkog prometa. Prije izrade modela novog sustava potrebno je detaljno pojasniti sustave neizrazitog zaključivanja i njihove zakonitosti. Također je potrebno opisati mogućnost primjene inteligentnih transportnih sustava u procesu upravljanja željezničkim prometom. Rad je podijeljen u šest cjelina:

1. Uvod
2. Sustavi neizrazitog zaključivanja
3. Primjena inteligentnih transportnih sustava u procesu upravljanja željezničkim prometom
4. Izrada novog modela sustava podrške pri regulaciji željezničkog prometa temeljenog na neizrazitoj logici
5. Simulacijska analiza rada sustava podrške pri regulaciji željezničkog prometa
6. Zaključak

U drugom poglavlju opisan je razvoj sustava neizrazitog zaključivanja te su navedene vrste tih sustava. Opisani su procesi zaključivanja u neizrazitom sustavu te zakonitosti takvog zaključivanja. Navedene su glavne prednosti i nedostaci tih sustava, kao i mogućnost njihove primjene.

U trećem poglavlju opisan je sustav centraliziranog upravljanja željezničkim prometom te su navedene mogućnosti primjene inteligentnih transportnih sustava prilikom takvog upravljanja. Također je opisan sustav automatskog postavljanja putova vožnje koji predstavlja preteču razvoja inteligentnih transportnih sustava u željezničkom prometu.

U četvrtom poglavlju opisan je novi model sustava neizrazitog zaključivanja koji služi za pružanje podrške pri odlučivanju u procesu regulacije željezničkog prometa. Također je opisan proces izrade navedenog sustava u programu Matlab te je prikazan primjer djelovanja sustava.

U petom poglavlju analiziran je rad modela sustava podrške pri odlučivanju u procesu regulacije željezničkog prometa u programu OpenTrack. Analiza rada sustava izvršena je simuliranjem specifičnih prometnih situacija na modelu željezničke infrastrukture te praćenjem dobivenih učinaka nakon implementacije upravljačkih rješenja dobivenih pomoću novog modela sustava podrške.

## **2. SUSTAVI NEIZRAZITOG ZAKLJUČIVANJA**

### **2.1. Razvoj i vrste sustava neizrazitog zaključivanja**

Neizrazita logika i sustavi neizrazitog zaključivanja spadaju u područje umjetne inteligencije. Umjetna inteligencija je znanstvena disciplina temeljena na računalima i računalnim programima koja se ubrzano razvija i mijenja. Zbog toga postoje mnoge definicije umjetne inteligencije, a sve ukazuju na to da je umjetna inteligencija (eng. Artificial Intelligence - AI) znanstvena disciplina koja se bavi oblikovanjem računalnih sustava koji primjenjuju inteligentna svojstva ljudskog ponašanja i koji bi trebali uspješno zamijeniti ljude u odrađivanju određenih zadataka. Primarni cilj umjetne inteligencije je proizvesti inteligentne strojeve koji mogu razmišljati, donositi odluke, rješavati probleme i što je najvažnije učiti. Umjetna inteligencija je interdisciplinarno područje koje za ozbiljno istraživanje zahtijeva znanje iz računalnih znanosti, lingvistike, psihologije, biologije, filozofije i raznih drugih znanosti. Umjetna inteligencija može se podijeliti na jaku i slabu umjetnu inteligenciju. Jaka umjetna inteligencija temeljena je na vjerovanju da se umjetna inteligencija može razviti do te razine da ima mogućnost razmišljanja, zaključivanja i funkcioniranja na razini ljudskog bića, te da ima osjećaje i samosvijest. Slaba umjetna inteligencija temeljena je na tezi da stvaranje ljudske razine inteligencije u strojevima nije moguće, ali moguće ju je razviti do te razine da može rješavati mnoge stvarne probleme. [1], [2]

Neizrazita logika i sustavi neizrazitog zaključivanja javljaju se zbog potrebe prevođenja ljudskog načina zaključivanja u oblik matematičkog opisa koji se može koristiti u računalnom programu. Naime bilo je potrebno riješiti problem koji stvaraju razlike u načinu zaključivanja čovjeka i računala. Računala u načinu zaključivanja koriste izraziti logički blok koji se temelji na preciznoj vrijednosti ulaza iz koje se izvodi nedvosmislena izlazna vrijednost, koja može biti „ISTINA“ odnosno „LAŽ“. Te vrijednosti bi se u ljudskom načinu razmišljanja mogle prevesti sa „DA“ i „NE“. Pošto čovjek u svom načinu razmišljanja ne koristi samo ove dvije vrijednosti, nego i druge vrijednosti koje se nalaze između, došlo je do potrebe razvoja sustava koji će bolje opisivati ljudski način razmišljanja. Tu se javlja neizrazita logika koja podrazumijeva računanje s varijablama, koje umjesto brojeva predstavljaju riječi definirane kao neizraziti skupovi.[1]

Proučavanjem složenih sustava došlo se do zaključka da se povećanjem složenosti sustava smanjuje mogućnost preciznog i brzog zaključivanja, sve do granice nakon koje zbog nedovoljne brzine zaključivanja velika preciznost sustava gubi smisao. U većini slučajeva za uspješno rješavanje nekog problema bitnija je brzina njegovog rješavanja od preciznosti rješenja.[1]



U svakodnevnom životu postoji velik broj primjera gdje je potrebno brzo rješavanje određenog problema. Takav primjeri vidljiv je iz situacije u kojoj se na ulici nalaze čovjek A i čovjek B te na čovjeka B pada težak predmet s obližnje zgrade. U toj situaciji čovjeku B bitnije je da ga čovjek A kratkim upozorenjem, „Pazi“, obavijesti da na njega pada težak predmet, nego da mu govori: „predmet težine 500 kila, koji pada brzinom 40 metara u sekundi, približava se tvojoj glavi“. Kratkim upozorenjem čovjek A bi čovjeka B uspio na vrijeme obavijestiti da se makne s mjesta na kojem mu prijeti pad teškog predmeta, dok kod pružanja opširnih informacija čovjek B ne bi imao vremena skloniti se od padajućeg predmeta. [3]

Zbog potrebe za brzim rješavanjem određenih problema razvila se neizrazita logika koja predstavlja proširenje Boolove logike. Neizrazita logika, za razliku od Boolove logike kod koje se sve može izraziti pomoću binarnih vrijednosti, te vrijednosti zamjenjuje stupnjem istinitosti. Najveća razlika između Boolove i neizrazite logike vidljiva je u određivanju pripadnosti nekog elementa određenom skupu. Dok kod Boolove logike neki element može pripadati samo jednom skupu, u neizrazitoj logici se određuje stupanj pripadnosti te taj element može djelomično pripadati u više definiranih neizrazitih skupova. [1]

Neizrazita logika zbog svojih navedenih karakteristika može se definirati kao metoda zaključivanja koja je slična ljudskom načinu zaključivanja te imitira postupak donošenja odluka kod ljudi, koji je često neprecizan i ima puno više vrijednosti od klasičnih vrijednosti korištenih u računalima („DA“ i „NE“). Sustavi neizrazitog zaključivanja mogu se definirati kao ekspertni sustavi koji postupak donošenja odluka temelje na neizrazitoj logici. [1], [4]

Sustavi neizrazitog zaključivanja mogu se podijeliti na dvije osnovne vrste, koje se koriste u programu Matlab [5]:

- Mamdani
- Sugeno

Dvije navedene vrste sustava vrlo su slične u većini dijelova. Tako imaju jednak način pridruživanja vrijednosti funkcije pripadnosti, kao i primjenjivanja neizrazitih logičkih operatora. Glavna razlika između dva navedena sustava je u načinu na koji se definiraju izlazne vrijednosti nakon metode agregacije. [6]

Mamdani sustav neizrazitog zaključivanja najviše je zastupljen te je jedan od prvih sustava koji je koristio neizrazitu logiku. Predložen je od strane Ebrahima Mamdanija kao pokušaj upravljanja kombinacijom parnih kotlova i bojlera primjenom skupa jezičnih kontrolnih pravila dobivenih od strane eksperata. U Mamdani sustavu neizrazitog zaključivanja izlazna vrijednost nakon metode agregacije mora biti definirana kao neizraziti logički skup. Zbog toga je nakon metode agregacije svakoj izlaznoj vrijednosti potrebno izračunati pripadnu čvrstu vrijednost. Za razliku od toga Sugeno metoda zaključivanja u izlaznim vrijednostima nakon metode agregacije omogućuje korištenje okomite linearne funkcije pripadnosti, što je u mnogim slučajevima učinkovitije od korištenja neizrazitih logičkih skupova. Takva funkcija pripadnosti, zbog pojednostavljenja u odnosi na općenitiju Mamdani metodu, može povećati učinkovitost procesa računanja pripadne čvrste vrijednosti. Sugeno metoda može se koristiti za svaki model sustava neizrazitog zaključivanja u kojem je izlazna funkcija pripadnosti linearna ili konstantna. [5]

Budući da su Sugeno sustavi kompaktniji i računski učinkovitiji od Mamdani sustava oni omogućuju uporabu adaptivnih tehnika prilikom izrade neizrazitih logičkih modela. Ove adaptivne tehnike mogu se koristiti za prilagodbu funkcija pripadnosti, tako da sustav neizrazitog zaključivanja bolje obrađuje podatke. [7]

Prednosti Sugeno sustava vidljive su iz sljedećih karakteristika tih sustava [7]:

- Sugeno sustavi su računski učinkovitiji
- Rade dobro s linearnim tehnikama, kao što je npr. PID kontroler koji ima široku uporabu, a može se koristiti i za tempomat u automobilima
- Rade dobro s tehnikama optimizacije i adaptivnim tehnikama
- Jamče kontinuitet izlaznih površina
- Prikladni su za matematičke analize

Prednosti Mamdani sustava su [7]:

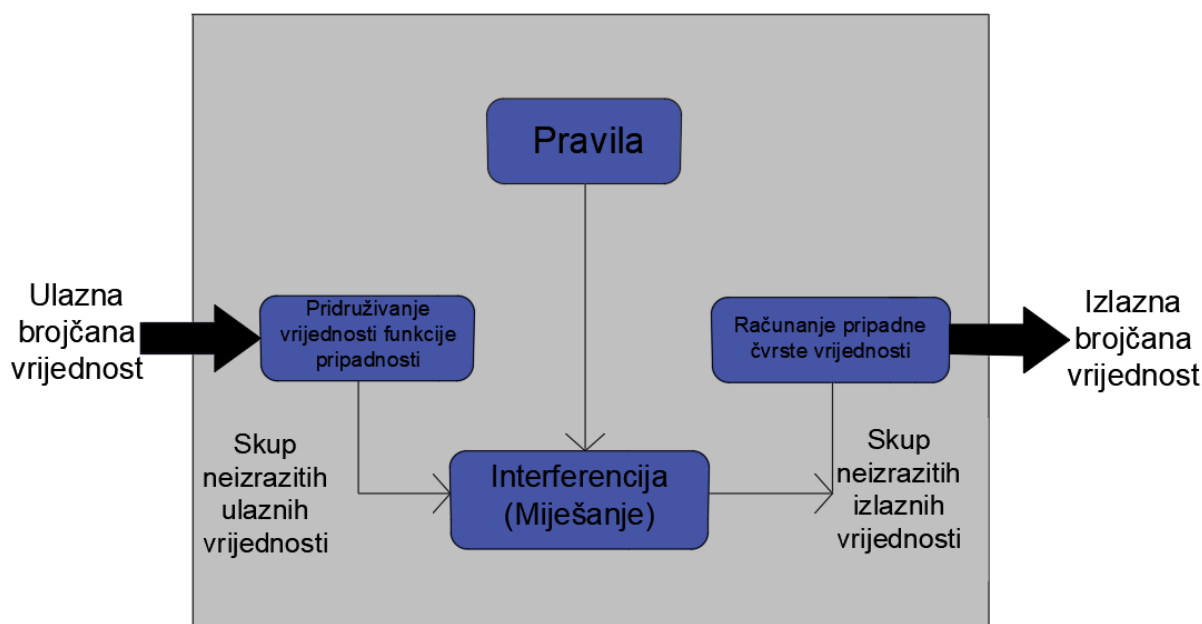
- Sustavi su intuitivni
- Imaju masovnu prihvaćenost
- Dobro su prilagođeni ljudskom unosu podataka

## 2.2. Proces zaključivanja u neizrazitom sustavu

Proces zaključivanja u neizrazitom sustavu odvija se u nekoliko osnovnih koraka [1], [4]:

- Pridruživanje vrijednosti funkcije pripadnosti
- Interferencija (miješanje)
- Agregacija (združivanje)
- Računanje pripadne čvrste vrijednosti

Na Slici 1. vidljiv je pojednostavljeni grafički prikaz glavnih procesa koji se vrše u sustavu neizrazitog zaključivanja. Valja naglasiti da se agregacija vrši nakon interferencije te prije računanja pripadne čvrste vrijednosti. U procesu interferencije koriste se pravila koja su pohranjena u bazi pravila, a stvorena su od strane stručnjaka. Ulaz i izlaz iz sustava su brojčane vrijednosti.



**Slika 1.** Pojednostavljeni prikaz glavnih procesa sustava neizrazitog zaključivanja


Izvor: [1], [4]

### 2.2.1. Pridruživanje vrijednosti funkcije pripadnosti

Prvi korak u procesu neizrazitog logičkog zaključivanja je pridruživanje vrijednosti funkcije pripadnosti. Ulaz u sustav predstavljaju brojčane vrijednosti kojima je potrebno pridružiti vrijednost pripadnosti određenim neizrazitim logičkim skupovima, kako bi se mogao vršiti daljnji proces neizrazitog logičkog zaključivanja. Taj proces pridruživanja vrijednosti vrši se pomoću funkcije pripadnosti. Funkcija pripadnosti neizrazitog logičkog skupa može se definirati kao krivulja koja svakoj mogućoj vrijednosti ulaza u sustav pridjeljuje vrijednost pripadnosti između 0 i 1. Funkcija pripadnosti neizrazitom logičkom skupu značajno se razlikuje od funkcije pripadnosti klasičnom logičkom skupu, koja predstavlja točnu granicu tj. okomiti pravac koji dijeli potpunu pripadnost određenom skupu (1), od potpune isključenosti iz tog skupa (0). [8], [9]

Kao što je već navedeno kod pridruživanja vrijednosti funkcije pripadnosti vrijednost pripadnosti pridružuje se određenim neizrazitim logičkim skupovima. Zbog boljeg shvaćanja neizrazitih logičkih skupova prvo treba dobro shvatiti definiciju klasičnog skupa. Klasični skup može se definirati kao „spremnik“ koji u cijelosti uključuje ili isključuje bilo koji element. Klasični skup nosi taj naziv zato što je već dugo u uporabi, a prvi ga je definirao Aristotel. Primjenom Aristotelove definicije podrazumijeva se da svi predmeti koji postoje mogu ili u potpunosti pripadati određenom skupu ili mu u potpunosti ne pripadati. Za razliku od klasičnog skupa, neizrazitom logičkom skupu elementi ne moraju u potpunosti pripadati ili u potpunosti biti isključeni iz tog skupa. Taj skup je bolje primjenjiv u ljudskom načinu razmišljanja. Za primjer se može uzeti skup dana koji čine vikend. Subota i nedjelja u potpunosti pripadaju vikendu, dok se petak nalazi na granici. Mnogi ljudi kažu da petak pripada vikendu, iako on tehnički spada u radne dane. Ovakav način svrstavanja u klasičnom skupu ne bi bilo moguće primijeniti, te bi se petak morao ili u potpunosti pridijeliti skupu dana vikenda ili u potpunosti isključiti iz tog skupa. [8]


Takva razlika u pridjeljivanju pripadnosti dana vikendu vidljiva je na Slici 2. Na lijevoj slici vidljivo je pridjeljivanje vrijednosti pripadnosti klasičnom skupu, gdje ta pripadnost može biti 1 ili 0 („DA ili NE“). Takav način zaključivanja i pridjeljivanja vrijednosti koriste i računala. Na lijevoj slici vidljiv je način pridjeljivanja vrijednosti pripadnosti neizrazitom logičkom skupu, gdje ta vrijednost može biti u rasponu od 0 do 1.



**Slika 2.** Pridjeljivanje vrijednosti pripadnosti klasičnom i neizrazitom logičkom skupu

Izvor: [8]

Neizraziti logički skupovi od presudne su važnosti za izradu sustava neizrazitog zaključivanja u programu Matlab. U tom programu jedan od prvih koraka je kreirati ulazne varijable te ih podijeliti na neizrazite logičke skupove definirane funkcijama pripadnosti. Primjer podjele raspona jednog ulaza na funkcije pripadnosti kojima su definirani neizraziti logički skupovi vidljiv je na Slici 3. U ovom primjeru ulaz u sustav neizrazite logike podijeljen je na 5 neizrazitih skupova. Tako ulazna varijabla može pripadati skupovima jako male, male, srednje, velike i jako velike vrijednosti. Također je moguće vidjeti interval funkcije pripadnosti [0 1].




**Slika 3.** Logički skupovi u programu Matlab

Najbolji primjer potrebe za korištenjem funkcije pripadnosti neizrazitom logičkom skupu je određivanje visine određene osobe, tj. dijeljenje ljudi na visoke i niske. Klasični skup sa svojom funkcijom pripadnosti u tom primjeru ne bi bio primjenjiv, zato što bi to podrazumijevalo da se ljudi grupiraju u skupinu visokih i niskih ljudi temeljeno na jednoj točno određenoj visini. U tom slučaju bi, na primjer, svi ljudi koji su viši od 180 centimetara spadali u skupinu visokih ljudi, a svi ljudi ispod te visine bili bi isključeni iz te skupine i spadali u niske ljude, što nije zadovoljavajuća podjela za ovaj slučaj.

Korištenjem neizrazite funkcije pripadnosti ne bi postojala točno određena visina, tj. točno određena granica koja dijeli visoke ljude od niskih, već bi se ljudima određivalo u kojem postotku pripadaju skupini visokih ljudi te ih se na temelju toga klasificiralo u odnosu na njihovu visinu. Tako bi postojalo puno više klasifikacija za visinu osim visokog i niskog, kao što je umjereno nisko, prilično nisko, umjereno visoko, prilično visoko itd. [8]

Navedena funkcija pripadnosti neizrazitom logičkom skupu vidljiva je na Slici 4. Vidljivo je da ljudi visine 160 centimetara imaju vrijednost funkcije pripadnosti samo 0.30 te se zbog toga mogu klasificirati kao prilično niske osobe. Osobe visine 190 centimetara imaju vrijednost funkcije pripadnosti 0,95, što znači da skoro u potpunosti pripadaju skupini visokih ljudi te se mogu klasificirati kao jako visoke osobe.



**Slika 4.** Funkcija pripadnosti neizrazitom logičkom skupu visokih ljudi


Izvor: [8]

Funkcije pripadnosti mogu biti različitih oblika, koji se primjenjuju temeljeno na specifičnoj problematici koju sustav neizrazitog zaključivanja mora riješiti. Program Matlab nudi 11 različitih tipova funkcija pripadnosti. Ovih 11 funkcija izgrađeno je od nekoliko osnovnih funkcija [8]:

- Jednodijelne linearne funkcije
- Gaussova krivulja (normalna raspodjela)
- Sigmoidna krivulja
- Kvadratne i kubične polinomne krivulje

Najjednostavnije funkcije pripadnosti temelje se na jednodijelnim linearnim funkcijama. Najjednostavnije od tih funkcija su funkcije u obliku trokuta, koje se u Matlabu nalaze pod nazivom „trimf“. Trapezoidalna funkcija također spada u linearne funkcije te u Matlabu nosi naziv „trapmf“. Ona za razliku od trokuta ima još jedan dodatni brid na vrhu funkcije. Navedene linearne funkcije imaju prednost jednostavnosti te se često koriste prilikom formiranja sustava neizrazitog zaključivanja. [8]

Dvije navedene funkcije pripadnosti vidljive su na Slici 5. Funkcija pripadnosti u obliku trokuta ima tri točke u kojima se može prilagođavati položaj te funkcije u rasponu vrijednosti ulazne varijable sustava, dok funkcija u obliku trapeza ima 4 točke za prilagođavanje položaja i raspona funkcije.



**Slika 5.** Linearne funkcije pripadnosti

Izvor: [8]

Dvije funkcije pripadnosti temeljene na Gaussovoj krivulji su jednostavna i dvostrana Gaussova krivulja. Navedene funkcije pripadnosti u programu Matlab nalaze se pod nazivom „gaussmf“ i „gauss2mf“. Za razliku od funkcija pripadnosti temeljenih na Gaussovoj krivulji, funkcija pripadnosti u obliku zvona sadrži još jedan parametar u kojem se krivulja može prilagođavati. Ova funkcija u programu Matlab nalazi se pod nazivom „gbellmf“. Zbog njihovih zaobljenih bridova ove funkcije se često upotrebljavaju za definiranje neizrazitih logičkih skupova. Glavne prednosti navedenih funkcija su zaobljenost bridova te različitost njihove vrijednosti od nule u svakoj točki. Navedene krivulje nemaju mogućnost definiranja asimetričnih funkcija, pa se radi te potrebe javljaju sigmoidne krivulje. Također za definiranje funkcija pripadnosti mogu se koristiti kvadratne i kubične polinomne funkcije. [8]

### 2.2.2. Interferencija

Nakon što su ulaznim varijablama pridijeljene funkcije pripadnosti poznate su vrijednosti u kojima svaki dio prethodnika (prvi dio IF-THEN pravila) zadovoljava svako pravilo. Ako prethodnik pravila ima više od jednog dijela, primjenjuje se neizraziti logički operator kako bi se dobila jedna vrijednost koja predstavlja rezultat prethodnika pravila. Ta vrijednost se nakon toga koristi za dobivanje izlazne vrijednosti IF – THEN pravila. Tako ulaz ovog neizrazitog logičkog operatora čine dvije ili više vrijednosti funkcije pripadnosti dobivenih iz ulaznih varijabli, dok izlaz čini jedinstvena vrijednost funkcije pripadnosti. [9]

Logički operatori koji se koriste su I, ILI i NE. Ti operatori se kod neizrazite logike razlikuju od klasičnih logičkih operatora. Za razliku od klasičnih logičkih operatora, gdje se računa s vrijednostima 0 i 1, neizraziti logički operatori računaju sa svim vrijednostima koje se nalaze u rasponu od 0 do 1. Do potrebe takvog računanja dolazi zbog toga što neizrazita logika u biti predstavlja proširenje Boolove logike. Tako se klasični logički operatori u neizrazitoj logici mogu koristiti samo za krajnje vrijednosti, 0 i 1. [8] Računske operacije klasičnih logičkih operatora vidljive su u Tablici 1.

**Tablica 1.** Klasični logički operatori

A	B	A i B	A	B	A ili B	A	ne A
0	0	0	0	0	0	0	1
0	1	0	0	1	1	1	0
1	0	0	1	0	1	operator NE	
1	1	1	1	1	1		
operator I			operator ILI				

Izvor: [8]

Zbog računanja u neizrazitoj logici, prikazanu tablicu logičkih operatora potrebno je proširiti tako da može računati sa svim vrijednostima koje se nalaze između 0 i 1. U tu svrhu operator I može se proširiti dodavanjem funkcije min (minimum). Tako se za varijable A i B logički operator A I B proširuje funkcijom minimuma koja glasi  $\min(A,B)$ . Istim postupkom logički operator ILI može se proširiti dodavanjem funkcije max (maksimum), tako da za varijable A i B ta funkcija poprima oblik  $\max(A,B)$ . Također je moguće logični operator negacije (NE A) proširiti dodavanjem funkcije  $1-A$ . [8]

U Tablici 2. vidljivo je kako se vrijednosti istinitosti ne mijenjaju dodavanjem navedenih funkcija u logičke operatore. Jedina razlika je u tome što takvo dodavanje funkcija u logičke operatore omogućuje računanje sa svim vrijednostima između 0 i 1.




**Tablica 2.** Neizraziti logički operatori

A	B	$\min(A,B)$	A	B	$\max(A,B)$	A	$1-A$
0	0	0	0	0	0	0	1
0	1	0	0	1	1	1	0
1	0	0	1	0	1	operator NE	
1	1	1	1	1	1		
operator I			operator ILI				

Izvor: [8]

Na Slici 6. grafički su prikazani logički operatori navedeni u tablicama. Logički operatori primjenjuju se kako bi se od dva neizrazita logička skupa dobio jedan, temeljeno na pravilima određenih operatora. Na gornjem dijelu slike vidljivi su operatori koji se primjenjuju na neizrazitim logičkim skupovima koji imaju samo dvije krajnje vrijednosti (0 i 1). Ti skupovi mogu se poistovjetiti s klasičnim skupovima. Na donjem dijelu slike vidljiva je primjena operatora na neizrazitim logičkim skupovima koji imaju više od dvije vrijednosti.



**Slika 6.** Primjena neizrazitih logičkih operatora

Izvor: [8]

Navedeni logički operatori mogu se nadograditi, da budu primjenjivi u neizrazitoj logici, i drugim matematičkim funkcijama. Tako se operator I, osim funkcijom min (minimum), može nadograditi i funkcijom prod (produkt ili umnožak). Operator ILI, osim funkcijom max (maksimum), može se nadograditi i funkcijom probabilističko ILI (probor). Probabilističko ILI, također poznato kao algebarska suma, računa se po formuli [9]:

- $\text{probor}(a,b) = a + b - ab$

Nakon određivanja vrijednosti prethodnika pravila potrebno je odrediti težinu svakog pravila. Svako pravilo može imati težinu u rasponu od 0 do 1, te se ta težina primjenjuje na prethodnik pravila. Ako je težina pravila 1 ona ne mijenja prethodnik pravila, dok vrijednosti težine pravila manje od 1 mijenjaju vrijednost prethodnika. Težina pravila ukazuje na stupanj istinitosti tog pravila, a pravilo je u potpunosti istinito ako je težina pravila jednaka 1. Zakonitosti interferencije, tj. zaključivanja u neizrazitom logičkom sustavu definiraju se pomoću IF – THEN pravila. Ta pravila su pohranjena u bazi znanja, a definirana su od strane eksperta, na temelju njegovog iskustva. [9]

IF – THEN pravila su uvjetne izjave te pravilo vrijedi samo ako je zadovoljen uvjet na prethodniku. U neizrazitoj logici ta pravila poprimaju izraz [8]:

- Ako je x jednako A, onda je y jednako B

U tom izrazu A i B su jezične vrijednosti definirane pomoću neizrazitih logičkih skupova. X predstavlja ulaznu varijablu definiranu određenim rasponom, dok je y izlazna varijabla. IF (ako) dio pravila se zove prethodnik, a THEN (onda) dio pravila zaključak. Primjer tog pravila može glasiti [8]:

- Ako je hrana dobra, onda je napojnica prosječna

Pomoću ovog pravila računa se koliku napojnicu osoba treba ostaviti u restoranu, temeljeno na kvaliteti hrane. Riječ „dobra“ u biti predstavlja neizraziti logički skup koji ima određeni raspon vrijednosti između 0 i 1, tako da posrednik pravila pri računanju, pomoću funkcije pripadnosti, daje određeni broj između 0 i 1. Riječ „prosječna“ također predstavlja neizraziti logički skup, tako da zaključak pravila pridjeljuje cijeli neizraziti logički skup izlaznoj varijabli y. Općenito, ulaz IF – THEN pravila predstavlja trenutna vrijednost ulazne varijable u sustav, dok izlaz čini cijeli neizraziti logički skup. [8]

Tumačenje, tj. primjena IF – THEN pravila sastoji se od dva koraka [8]:


- Vrednovanje prethodnika pravila – pridjeljivanje pripadne čvrste vrijednosti neizrazitim logičkim skupovima, te korištenje neizrazitih logičkih operatora
- Primjena rezultata prethodnika na zaključak pravila

Drugi korak primjene IF – THEN pravila naziva se implikacija. Tijekom primjene IF – THEN pravila prethodnik se implicira, tj. utječe na zaključak pravila. Prilikom provođenja procesa implikacije u binarnoj logici bi vrijedila zakonitost: ako je prethodnik istina, onda je zaključak također istina. U neizrazitoj logici, koja dovodi do mogućnosti korištenja svih vrijednosti funkcije pripadnosti između 1 i 0, ta bi zakonitost glasila: ako je prethodnik istina za neki stupanj vrijednosti funkcije pripadnosti, onda je zaključak također istina za taj isti stupanj. U oba slučaja vrijedi da ako je prethodnik netočan, tj. vrijednosti 0, onda je zaključak neodređen. [8]

Kao što je već objašnjeno, prethodnik pravila može se sastojati od više dijelova, što dovodi do potrebe objedinjavanja tih dijelova pomoću logičkih operatora. Isto tako se i zaključak pravila može sastojati od više dijelova. Takav primjer vidljiv je iz sljedećeg pravila:

- Ako je temperatura niska, ventil tople vode je otvoren i hladne vode je zatvoren

U ovom slučaju prethodnik djeluje jednako na sve dijelove zaključka. Kao što je već spomenuto prethodnik djeluje na zaključak procesom implikacije. Taj proces vrši se tako da vrijednost prethodnika, koja je broj od 0 do 1, oblikuje neizraziti logički skup definiran u zaključku. Na neizraziti logički skup najčešće se utječe pomoću funkcije min (minimum), gdje je taj skup skraćen ovisno o vrijednosti prethodnika. Taj utjecaj može se vršiti i pomoću funkcije prod (product), gdje se vrši skaliranje neizrazitog logičkog skupa. Navedeni postupak djelovanja prethodnika na zaključak pomoću funkcije minimuma vidljiv je na Slici 7. [8]



**Slika 7.** Primjer IF-THEN pravila

Izvor: [9]

### 2.2.3. Agregacija

Budući da se odluke temelje na testiranju i korištenju više pravila, dolazi do potrebe objedinjavanja izlaza svih korištenih pravila. To se vrši procesom Agregacije, kojom se neizraziti skupovi, koji predstavljaju izlaze svakog pravila, objedinjavaju u jedan neizraziti skup. Agregacija se vrši samo jednom za svaku izlaznu varijablu, neposredno prije računanja pripadne čvrste vrijednosti. Ulaz procesa agregacije čine neizraziti logički skupovi oblikovani implikacijom, dok izlaz čini jedan logički skup za svaku izlaznu varijablu. [9]

Za agregaciju, u programu Matlab, moguće je koristiti tri metode [9]:

- max (maksimum)
- probor (probabilističko ILI)
- sum (zbroy izlaznih neizrazitih logičkih skupova)

### 2.2.4. Računanje pripadne čvrste vrijednosti

Iako primjena neizrazitih logičkih skupova u procesu zaključivanja pomaže pri stvaranju i procjeni pravila, željena izlazna vrijednost sustava neizrazitog zaključivanja je brojčana vrijednost. Nakon agregacije završni neizraziti logički skup obuhvaća raspon vrijednosti, što dovodi do potrebe vršenja procesa računanja pripadne čvrste vrijednosti da bi se dobila jedna izlazna brojčana vrijednost iz neizrazitog logičkog skupa. Ulaz procesa računanja pripadne čvrste vrijednosti čini neizraziti logički skup, koji se dobije agregacijom izlaznih skupova svih primijenjenih pravila, a izlaz čini brojčana vrijednost. [9]

U programu Matlab postoji pet metoda za računanje pripadne čvrste vrijednosti, a to su: centroid (središnji), bisector (simetrični), middle of maximum (prosjeak maksimalne vrijednosti izlaznog skupa), largest of maximum (najveći od maksimuma), smallest of maximum (najmanji od maksimuma). Najviše se koristi metoda izračunavanja centroida, kojom se računa središnja vrijednost ispod područja krivulje. [9]

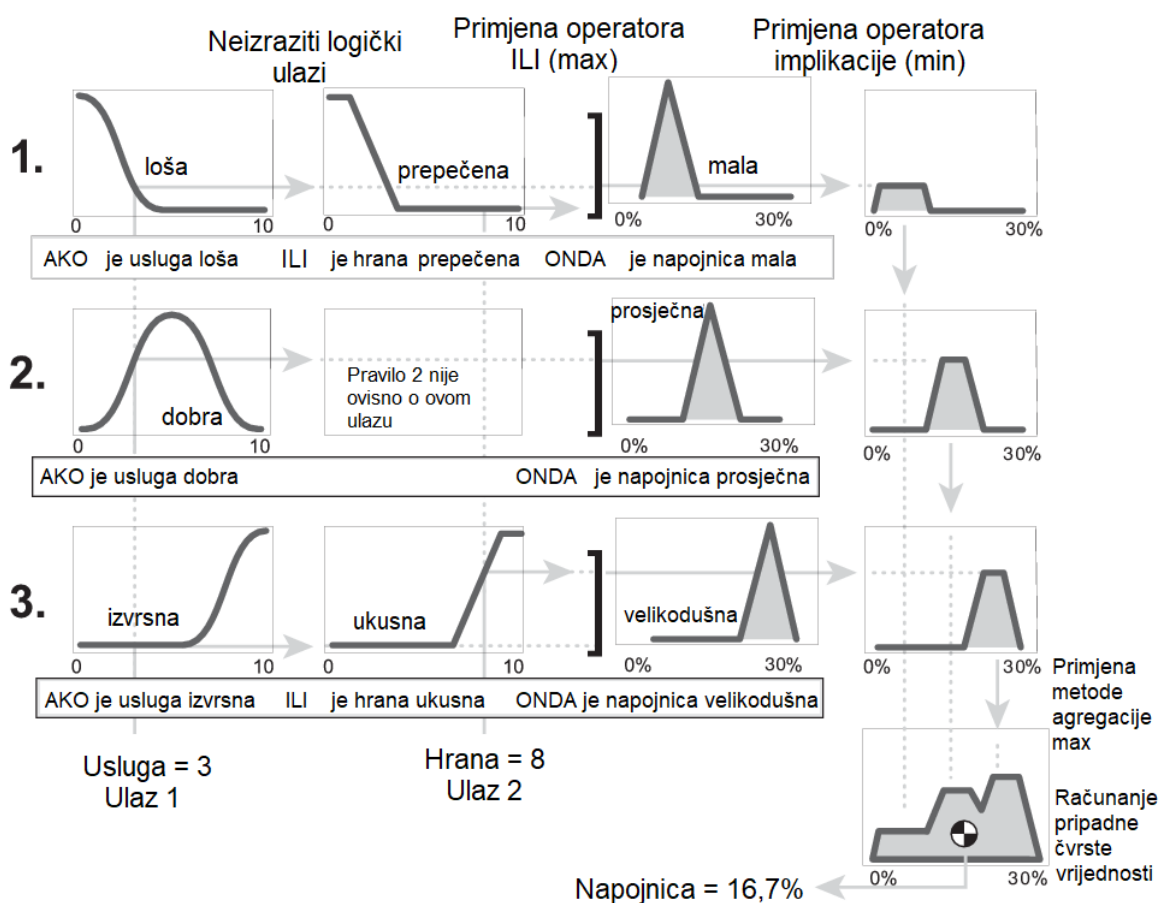
### 2.2.5. Primjer procesa zaključivanja u neizrazitom sustavu

Za primjer procesa zaključivanja u neizrazitom sustavu uzet je klasičan primjer problema davanja napojnice. Sustav se sastoji od dvije ulazne vrijednosti, tri pravila i jedne izlazne vrijednosti. Ulazne vrijednosti su usluga, koja ima raspon od 0 do 10 i hrana, koja također ima raspon od 0 do 10. Izlaznu vrijednost čini napojnica, koja može

biti u rasponu od 0% do 30 %. Pravila označavaju odnos između ulaznih i izlaznih vrijednosti te glase [9]:

- Ako je usluga loša ili je hrana prepečena, onda je napojnica mala
- Ako je usluga dobra, onda je napojnica prosječna
- Ako je usluga izvrsna ili je hrana ukusna, onda je napojnica velikodušna

Na Slici 8. vidljivi su dijelovi procesa zaključivanja navedenog neizrazitog sustava. Vidljivo je da se za objedinjavanje neizrazitih logičkih skupova u prethodniku pravila koristi logički operator ILI, tj. funkcija maksimum. Za proces implikacije koristi se operator minimum, pomoću kojeg se oblikuje neizraziti logički skup u zaključku pravila. Nakon implikacije vrši se metoda agregacije, pomoću metode maksimuma, gdje se uzimaju maksimumi neizrazitih logičkih skupova izlaznih varijabli svih korištenih pravila te se objedinjavaju u jedan neizraziti logički skup. Računanje pripadne čvrste vrijednosti vrši se pomoću metode centroida te se računa središnja vrijednost objedinjene neizrazite logičke funkcije.



**Slika 8.** Postupci procesa zaključivanja u neizrazitom sustavu

Izvor: [9]

## **2.3. Prednosti i nedostaci sustava neizrazitog zaključivanja te mogućnosti njihove primjene**

Sustavi neizrazitog zaključivanja mogu se primjenjivati u različite svrhe te ugrađivati u sustave različitih veličina i mogućnosti. Primjenu takvog sustava moguće je naći od malih mikro kontrolera do velikih, umreženih, upravljačkih sustava. [4]

Neizrazita logika može biti korisna u komercijalne i praktične svrhe. Pomoću neizrazite logike mogu se upravljati različiti radni strojevi, kao i proizvodi koji se koriste u komercijalne svrhe. Neizrazita logika se koristi kada je potrebno dati rezultate u relativno kratkom vremenu, te kada se od tih rezultata ne zahtijeva velika točnost. Neizrazita logika može se koristiti kao pomoć pri rješavanju različitih inženjerskih problema. [4]

Kao i svaki drugi sustav, sustav neizrazitog zaključivanja ima svoje prednosti i nedostatke. Neke od prednosti takvog sustava su [3], [4]:

- Matematički pojmovi unutar neizrazitog logičkog zaključivanja vrlo su jednostavni
- Sustav neizrazitog zaključivanja jednostavno je mijenjati i dorađivati te se takve promjene vrše dodavanjem i brisanjem pravila
- Sustav neizrazitog zaključivanja ne mora sadržavati vrlo precizne ulazne varijable
- Sustavi neizrazitog zaključivanja jednostavni su za konstruiranje i razumijevanje
- Neizrazita logika je rješenje složenih problema u svim područjima života, uključujući medicinu, jer sliči ljudskom rasuđivanju i odlučivanju
- Neizrazita logika temeljena je na prirodnom jeziku

Najveća prednost neizrazite logike vidljiva je u zadnjoj izjavi. Zbog toga što je neizrazita logika temeljena na prirodnom jeziku, koji ljudi svakodnevno koriste i koji je usavršavan tisućama godina, ta logika je učinkovita i jednostavna za korištenje. [3]

Sustavi neizrazitog zaključivanja nisu komplicirani za razumijevanje i konstruiranje zbog toga što se neizrazita logika bazira na korištenju načina zaključivanja koji je slični ljudskome. Zbog toga su takvi sustavi vrlo intuitivni. Glavni cilj navedenih sustava je brzo rješavanje određenog problema, koji bi inače zahtijevao ljudsku intervenciju prilikom rješavanja. Radi toga sustavi neizrazitog zaključivanja mogu se primjenjivati za pomoć raznom osoblju prilikom izvršavanja određenih zadataka, a u nekim slučajevima ih mogu i u potpunosti zamijeniti.

Neki od nedostataka sustava neizrazitog zaključivanja su [4]:

- Ne postoji sustavni pristup dizajniranju sustava neizrazitog zaključivanja
- Takvi sustavi su razumljivi samo kad su jednostavno konstruirani
- Prikladni su samo za probleme koji ne zahtijevaju visoku točnost rješenja

Zbog navedenih nedostataka može se reći da neizrazita logika nije lijek za sve probleme. Zbog toga što je neizrazita logika prikladan način povezivanja ulaznih i izlaznih varijabli, ta prikladnost se mora razmotriti prije svake uporabe neizrazite logike. U nekim slučajevima, ako postoje prikladnija rješenja, bolje je ne primjenjivati neizrazitu logiku. Međutim ako je pojedinac dobro upoznat s neizrazitom logikom, ta logika može biti vrlo korisna u rješavanju nepreciznih problema. [3]

Izrada neizrazitih logičkih sustava zahtijeva sudjelovanje eksperata koji dobro poznaju problematiku koju taj sustav mora rješavati, kao i eksperata koji imaju dobro poznavanje neizrazitih logičkih sustava. Njihova suradnja prilikom izrade sustava ključna je kako bi taj sustav mogao dobro funkcionirati i obavljati sve zadaće za koje je namijenjen.

Neizrazita logika, u kombinaciji s genskim algoritmima, ima velik potencijal za zamjenu ljudi prilikom izvršavanja određenih zadataka. Moguće ju je koristiti kao sustav podrške prilikom odlučivanja u slučajevima kad je potrebno smanjiti radno opterećenje određenog radnog mjesta. U željezničkom prometu može se primjenjivati kao sustav podrške u procesu odlučivanja prilikom dispečerskog upravljanja željezničkim prometom te u usavršavanju sustava za automatsko postavljanje putova vožnje. Navedeni načini upravljanja te sustavi u kojima je primjenjiva neizrazita logika navedeni su u poglavlju 3.

### **3. PRIMJENA INTELIGENTNIH TRANSPORTNIH SUSTAVA U PROCESU UPRAVLJANJA ŽELJEZNIČKIM PROMETOM**

Inteligentni transportni sustavi predstavljaju ekspertne računalne sustave temeljene na tehnikama umjetne inteligencije, kao što su neizrazita logika, genski algoritmi itd. Takvi sustavi mogu imati široku primjenu na željeznici, a moguće ih je koristiti u svrhu smanjenja radnog opterećenja djelatnika koji u stvarnom vremenu trebaju donositi odluke o načinu upravljanja prometom. Primjena takvih sustava najčešća je u procesu upravljanja željezničkim prometom, gdje pružaju podršku prilikom donošenja upravljačkih odluka. Takvi sustavi imaju velik potencijal za primjenu u centraliziranom upravljanju željezničkim prometom, gdje mogu biti primijenjeni kao sustavi podrške u odlučivanju. Navedeni sustavi također se mogu koristiti za unapređenje automatskog postavljanja putova vožnje.

#### **3.1. Centralizirano upravljanje željezničkim prometom**

Jedna od glavnih zadaća upravljanja željezničkim prometom je težnja ka nesmetanom, sigurnom i pouzdanom odvijanju željezničkog prometa. Pouzdanost izvršenja voznog reda je osnovni parametar iz kojeg je vidljiva kvaliteta upravljanja prometom i korištenja kapaciteta raspoloživih sredstava željeznice. U modernom upravljanju željezničkim prometom postoje i drugi pokazatelji učinkovitosti željezničkog prometa, kao što su povećanje kapaciteta pruga i kolodvora uz izbjegavanje velikih ulaganja u izgradnju nove infrastrukture, energetska učinkovitost vožnje vlakova te smanjenje ostalih troškova eksploatacijskih sustava uz povećanje kvalitete željezničke prijevozne usluge. Primjena suvremenih tehnologija nudi povećanje učinkovitosti upravljanja željezničkim prometom te zadovoljavanje navedenih parametara, koji se pred takvo upravljanje prometom postavljaju. Međutim takvo povećanje učinkovitosti upravljanja željezničkim prometom nije moguće kod mjesnog načina upravljanja putem prometnika, koje se i danas primjenjuje na prugama HŽ infrastrukture. To je pogotovo vidljivo na prugama s velikom gustoćom prometa. Zbog toga što prometnici nemaju uvid, niti mogućnost upravljanja prometom na širem području željezničke mreže, oni nisu u mogućnosti optimizirati izvođenje željezničkog prometa. Rješenje tog problema predstavlja uvođenje centara za središnje upravljanje željezničkim prometom te podjela pružne mreže na područja centraliziranog upravljanja. U takvom načinu upravljanja prometnike, koji su imali ovlast za mjesno upravljanje, zamjenjuje dispečer koji ima mogućnost upravljanja cijelim područjem željezničke mreže, koje spada pod njegov centar za dispečersko upravljanje prometom. Takav dispečer, koji vrši centralizirano upravljanje prometom naziva se i dispečer telekomande ili skraćeno TK dispečer. Širina područja koje spada pod jedan centar upravljanja ovisi o kompleksnosti upravljanja prometom, pa može obuhvaćati samo jedan dio pruge, cijelu prugu ili čak i više povezanih pruga u okviru željezničkog čvora.[1]



Sustav centraliziranog upravljanja željezničkim prometom šalje u središnji centar za upravljanje informacije o položaju svih vlakova na mreži željezničkih pruga koja je pod nadležnošću tog centra te pruža mogućnost postavljanja putova vožnje i upravljanja svim signalima i skretnicama, izravno iz tog centra. Najbitniji dio središnjeg centra za upravljanje prometom su sučelja te jedinice za upravljanje, koje su povezane s kolodvorima i vlakovima pomoću različite opreme, kao što su radio oprema, komandni telefoni, snimači dijagrama prometovanja vlakova itd. [10]

Na Slici 9. vidljiv je prikaz sučelja u centru za dispečersko upravljanje željezničkim prometom. Na sučeljima je prikazana shema kolodvora i pruga koje su pod nadležnosti dispečera, trenutni položaj vlakova na tom dijelu pruge, kao i planirani vozni red. Za dispečera je ključno da ima točne i pravovremene podatke kako bi mogao donijeti ispravnu odluku o upravljanju prometom. Dispečer na svojem radnom mjestu također posjeduje i službeni telefon, kojim kontaktira druge dispečere, prometnike i ostalo prometno izvršno osoblje, kada postoji potreba za provjerom određene informacije ili izdavanje naredbi i obavijesti.



**Slika 9.** Prikaz sučelja u centru za dispečersko upravljanje željezničkim prometom

Izvor: [1]

Centralizirano upravljanje željezničkim prometom prvi put se primjenjuje 1927. godine u Sjedinjenim Američkim Državama. Taj sustav je omogućavao dispečeru da kontrolira svim signalima i skretnicama, što je omogućavalo križanje vlakova bez potrebe njihovog zaustavljanja i izlaženja posade vlaka zbog prebacivanja skretnica. Kako bi znao kojim signalima i skretnicama upravljati, dispečer je morao znati položaj svakog vlaka na mreži. Te informacije dobivao je pomoću električnih impulsa. Signali i skretnice bili su u međusobnoj ovisnosti te su signali prikazivali aspekte ovisno o položaju skretnice. Signalima i skretnicama upravljalo se pomoću prekidača. Dispečeru su na raspolaganju bile dvije vrste prekidača, prekidači koji upravljaju skretnicama i oni koji upravljaju signalima. Prekidači kojima su se upravljale skretnice mogli su se postaviti u dva položaja, kojima se skretnica postavljala u pravac ili skretanje. Svjetla za obavijest davala su naznaku u kojem je položaju skretnica. Prekidačima za postavljanje signala, postavljali su se signali za oba smjera. Pošto su signali bili ovisni o položaju skretnica ovaj prekidač je ubiti samo davao naznaku iz kojeg smjera dolazi vlak. Taj prekidač imalo je tri položaja, jedan za svaki smjer vožnje, te središnji položaj koji bi sve signale postavio na crveno. Ovaj sustav bio je skuplji od sustava Automatskog pružnog bloka (APB), ali je bio puno učinkovitiji u pogledu iskorištenja kapaciteta pruge i učinkovitosti odvijanja prometa. Naime sustav automatskog pružnog bloka je automatski postavljao prostorne signale i obavještavao o zauzetosti kolosijeka, ali imao je manu da su se skretnice još uvijek morale postavljati ručno. Prednosti sustava centraliziranog upravljanja bile su tolike da je jednokolosiječna pruga opremljena tim sustavom imala 70 do 75 posto kapaciteta dvokolosiječne pruge, opremljene automatskim pružnim blokom. [11], [12]

U današnje vrijeme sustavi centraliziranog upravljanja tehnološki su napredovali od svoje prve primjene. Razvojem računalnih tehnologija javljaju se načini za puno bolje, brže i kvalitetnije pružanje podataka koji su dispečeru ključni za izvršavanje zadataka koji se pred njega stavljaju i donošenje upravljačkih odluka. Iako su se načini prikupljanja informacija, kao i samog davanja upravljačkih naredbi značajno promijenili, princip centraliziranog upravljanja ostao je isti, a to je da dispečer upravlja svim prometom na određenom dijelu pruge i odgovoran je za sigurno i nesmetano izvođenje planiranog voznog reda.


Iz primjera drugih zemalja, koje su uvele centralizirano upravljanje, moguće je vidjeti da je najveći utjecaj uvođenja takvog upravljanja vidljiv na prugama s većim intenzitetom prometa. Vidljivo je povećanje u redovitosti odvijanja prometa te povećanju učinkovitost otklanjanja poremećaja u prometu. Također je poboljšana efikasnost u radu izvršnog osoblja na željeznici te je optimizirana uporaba voznih sredstava. Usavršavanjem takvih sustava omogućilo se smanjenje izvršnog osoblja na međukolodvorima te su neki kolodvori postali nezaposjednuti. Takav trend doveo je do smanjenja troškova upravljanja željezničkim prometom, a pri tome se nije smanjila sigurnost i učinkovitost odvijanja prometa. [13]

Kao što je već rečeno, kod centraliziranog upravljanja željezničkim prometom glavnu ulogu ima dispečer. On na temelju ponuđenih podataka te svog znanja i iskustva donosi upravljačke odluke, koje značajno utječu na točno i nesmetano odvijanje željezničkog prometa. Kod takvog upravljanja prometom najbitnije je pravovremeno uočavanje i otklanjanje nastalih poteškoća koje imaju mogućnost uzrokovanja značajnijih poremećaja u nesmetanom odvijanju željezničkog prometa. Ovisno o organizaciji prometa na određenom dijelu pruge te tehničkim sredstvima, razlikuje se uloga dispečera i njegove ovlasti u zadaćama upravljanja prometa. [1]

Dispečer mora nadzirati promet kako bi mogao pravovremeno reagirati i otklanjati poteškoće na željezničkoj mreži, kako na svom dijelu mreže, tako i na okolnim dijelovima mreže koji mogu izravno utjecati na odvijanje prometa koji je pod njegovom nadležnošću. Pri tome mora uvažavati podatke iz voznog reda i podatke o trenutnom stanju u odvijanju željezničkog prometa. Dispečer na temelju određenih prioriteta donosi odluke o načinu kretanja vlakova na području mreže pod njegovom nadležnošću. Te prioritete donosi na temelju podataka o vlakovima te njihovim karakteristikama. Naime neki vlakovi su manje osjetljivi na kašnjenje, a neki više. To ovisi o vrsti i namjeni vlaka te o njegovom utjecaju na daljnje izvršavanje planiranog voznog reda. Posebni izazov dispečeru predstavlja to što kašnjenje samo jednog vlaka na mreži može uzrokovati značajnija kašnjenja ostalih vlakova. Njegov glavni cilj je upravljati prometom tako da vlakovi imaju što manje kašnjenje i da su što manja odstupanja od planiranog voznog reda. Kvaliteta izvršenog upravljanja prometom vidljiva je iz usporedbe grafikona stvarnog prometovanja vlakova koji se odvijao pod nadzorom dispečera s grafikonom planiranog voznog reda. [1]

Dispečer će najučinkovitije obavljati svoj posao ako je u mogućnosti, iz podataka koji mu se prikazuju, pravovremeno uočiti ili čak u nekim slučajevima predvidjeti nastajanje poteškoća u odvijanju prometa te ponuditi kvalitetna i pravovremena rješenja kako te poteškoće riješiti ili umanjiti njihove posljedice. Da bi to bio u mogućnosti, dispečer mora predvidjeti rasplet situacije nakon što poduzme određene mjere za rješavanje nastalog problema. Da bi riješio određeni problem dispečer ima mogućnost korigiranja predviđenog voznog reda. Tako može promijeniti mjesta stajanja određenim vlakovima, može odlučiti o smanjenju ili produženju vremena stajanja vlakova u određenom službenom mjestu, u situacijama kada to može pozitivno utjecati na rješavanje nastalog prometnog problema. [1]

Radi uspješnog praćenja i reguliranja prometa, dispečer mora imati pregled nad položajem svakog vlaka na pruzi. Taj podatak se prikazuje grafički, a osim podataka o položaju vlaka istovremeno se prikazuju i položaji svake pruge, kolodvora s namjenom njegovih kolosijeka i drugih elemenata koji su neophodni za upravljanje željezničkim prometom na mreži pruga koja je pod nadležnošću dispečera. Grafički prikaz navedenih podataka vidljiv je na Slici 10. Osim prikazanih podataka na Slici 10, dispečeru također moraju biti dostupni podatci o signalnim pojmovima signala, položaj skretnica, smjeru vožnje vlakova u svakom međukolodvorskom području itd. [1]



**Slika 10.** Prikaz položaja vlakova na dijelu pruge s centraliziranim upravljanjem

Izvor: [1]

U današnje vrijeme postoje dva načina određivanja položaja vlakova na mreži. Prvi način podrazumijeva identifikaciju i određivanje broja vlakova prilikom njihovog ulaska u područje centraliziranog upravljanja. Brojevi vlakovima dodijeljeni su prilikom njihovog formiranja. Pozicija vlakova na dispečerskom sučelju mijenja se koristeći informacije o zauzeću pojedinih prostornih odsjeka pruge, a te se informacije prikupljaju od signalno sigurnosnih uređaja postavljenih na pruzi. Informacije se automatski obrađuju te grafički prikazuju dispečeru. One se također mogu koristiti za praćenje kretanja vlakova, njihovo zadržavanje u prostornim odsjecima te ostalih podataka pomoću kojih se može automatski izraditi dijagram stvarnog prometovanja vlaka, koji je prikazom sličan grafu iz grafikona voznog reda. Problem kod ovog načina određivanja položaja vlakova javlja se ukoliko dođe do kvarova na signalno sigurnosnim uređajima te to onemogućuje pristizanje informacija pomoću kojih se određuje položaj vlakova na mreži. Tada dispečer u najkritičnijem trenutku gubi trenutni pregled nad stvarnim stanjem položaja vlakova, što mu uvelike stvara probleme u izvršavanju zadataka koji se pred njega stavljaju. [1]

U drugom načinu određivanja položaja vlaka, informacije o položaju vlaka šalju uređaji koji su smješteni u samom vlaku. Prijenos informacija vrši se radio putem. Takav način određivanja položaja vlakova nudi mogućnost kontinuiranog prikupljanja podataka o položaju vlaka u stvarnom vremenu, kao i o njegovoj brzini. Podaci se brže i kvalitetnije prenose i pretvaraju u prikaz vlaka na dispečerskom sučelju, što omogućava značajno lakše prepoznavanje i rješavanje nastalih prometnih problema. Takav način prikupljanja podataka omogućava ERTMS – ETCS sustav razine 2 i 3. Ovakav način određivanja položaja vlakova također je bolji zbog neovisnosti o pružnim signalno sigurnosnim uređajima. Sustav u trenutku kvara signalno sigurnosnih uređaja nastavlja pružati informacije neophodne za određivanje položaja vlakova i uspješno reguliranje prometovanja vlakova na pružnoj mreži. [1]

Obavljanje zadataka koji su stavljeni pred dispečera nije nimalo jednostavno te je uvijek popraćeno s puno kompleksnih poteškoća, pogotovo na prugama koje su blizu maksimalnog iskorištenja kapaciteta. Takve poteškoće u većini slučajeva su teško predvidive te zahtijevaju brzu reakciju dispečera radi njihovog rješavanja. Izazove za uspješno obavljanje dispečerova posla predstavlja i miješani promet, kod kojeg su značajne razlike glavnih karakteristika putničkih i teretnih vlakova, kao što su brzina, ubrzanje, kočenje, dužina, težina itd. Zbog značajnih razlika u brzini vrlo je kompleksno uskladiti prometovanje vlakova i osigurati nesmetano izvođenje planiranog voznog reda. Ako se sporiji teretni vlak nađe ispred bržeg putničkog, može doći do značajnijeg kašnjenja putničkog vlaka koje se može odraziti na ostale vlakove i poremetiti odvijanje prometa na cijeloj pružnoj mreži. Zbog navedenog razloga mješoviti promet pruža dodatno radno opterećenje te dispečer mora uzeti u obzir veći broj parametara prilikom donošenja upravljačkih odluka. Sve češći zahtjevi za izvanrednim prijevozom dispečerov posao čine još težim. [14]

Dispečer izvršava svoje zadaće vršenjem interakcije sa sustavom kontrole prometa, informacijskim sustavima i svojim okruženjem. Taj posao je vrlo složen zbog dinamičkih svojstava prometa koji se kontrolira. Prometovanje vlakova iznimno je dinamičan proces te je jako teško predvidjeti sve situacije koje se mogu dogoditi u tom procesu. Mjere kontroliranja prometa mogu se primijeniti samo u određenim vremenskim periodima tj. kad vlak prolazi određenim dijelovima pruge. Dispečer mora biti toga svjestan i s obzirom na to prilagoditi svoj rad i izvršavanje svojih odluka. Također problem predstavlja to što rezultati poduzetih mjera u nekim slučajevima nisu odmah vidljivi te takve mjere mogu utjecati na odvijanje prometa tijekom nekog dužeg vremena, zbog iznimno velike međuovisnosti prometovanja vlakova. Da bi dispečer mogao razumjeti trenutnu prometnu situaciju, on mora dobro razumjeti razvoj događaja koji je doveo do te situacije, koji su se poremećaji pojavili, te koje su prijašnje mjere poduzete itd. [14]

Iz svega navedenog može se zaključiti da je dispečerov posao vrlo kompleksan. Dispečer mora istovremeno pratiti velik broj parametara kako bi uspješno izvršavao zadatke koji se pred njega stavljaju. Također mora donositi pravovremene i ispravne odluke kako bi riješio probleme koji se javljaju prilikom odvijanju željezničkog prometa i koji su teško predvidljivi. Zbog toga dispečer ima značajno radno opterećenje, pogotovo u situacijama visokog iskorištenja kapaciteta pruge i u vršnim satima. Radno opterećenje, kao i velik broj različitih ljudskih faktora, može dovesti do pogrešaka dispečera pri donošenju odluka, što dovodi do značajnih problema pri izvršavanju voznog reda i nesmetanog prometovanja vlakova. Zbog toga dolazi do potrebe smanjenja radnog opterećenja dispečera.

Kao što je već spomenuto, radno opterećenje se manjim dijelom može smanjiti kvalitetnijim i preglednijim prikazom svih podataka koji su dispečeru potrebni za izvršavanje zadataka koji su pred njega stavljeni, kao i ergonomskom prilagodbom njegovog radnog mjesta. I nakon izvršenih poboljšanja radnog mjesta dispečer još uvijek ima značajno radno opterećenje zbog potrebe za donošenjem velikog broja upravljačkih odluka koje značajno utječu na odvijanje prometa. Radi smanjenja radnog opterećenja dispečera, moguće je izraditi ekspertne sustave koji će dispečeru pružiti podršku prilikom donošenja upravljačkih odluka. Navedene sustave moguće je izraditi pomoću neizrazite logike. Uporabom neizrazite logike moguće je izraditi ekspertni sustav koji ima karakteristike ljudskog razmišljanja te mogućnost donošenja određenih upravljačkih odluka umjesto dispečera, što bi dovelo do značajnog smanjenja njegovog radnog opterećenja. Takvi sustavi mogu dispečeru dati više solucija rješenja od kojih on mora izabrati najprihvatljivije. Ekspertni sustavi koji su izrađeni pomoću neizrazite logike također mogu u potpunosti zamijeniti dispečera u donošenju upravljačkih odluka. U tom slučaju dispečer ima nadzornu funkciju te samo mora potvrditi izvršenje odluke koje je donio ekspertni sustav. U nastavku ovog rada prikazan je model novog ekspertnog sustava, temeljenog na neizrazitoj logici, koji predstavlja sustav podrške dispečeru i ima ulogu smanjenja njegovog radnog opterećenja. Taj sustav ima mogućnost davanja prioriteta postavljanja putova vožnje prilikom ulaska vlakova u kolodvor.

### 3.2. Automatsko postavljanje putova vožnje

Kao što je već navedeno u poglavlju 3.1., zbog potrebe za boljim, kvalitetnijim i ekonomičnijim upravljanjem prometom dolazi do primjene centraliziranog upravljanja željezničkog prometa. U takvom načinu upravljanja pružna mreža dijeli se na više centara upravljanja, a u svakom centru upravljanja, ili dispečerskom centru, dispečer ima glavnu ulogu i kontrolira cjelokupno prometovanje vlakova. Iz centra za upravljanje postavljaju se svi putovi vožnje za pruge koje su pod nadležnošću tog centra. Prvotno je dispečer dobar dio svoje pažnje i svog vremena trebao usmjeriti na postupak postavljanja putova vožnje. Radi smanjenja radnog opterećenja dolazi do automatizacije tog procesa te dispečer može posvetiti više vremena donošenju upravljačkih odluka i optimizaciji prometovanja vlakova.

Uvođenje automatskog postavljanja putova vožnje omogućen je poluautomatski način upravljanja željezničkim prometom. Takvi sustavi sastoje se od tri postupka kojima izvršavaju svoju zadanu funkciju [1]:


- Automatski odabir puta vožnje za vlak u vremenu prije njegovog nailaska na mjesto početka zaustavnog puta do kraja aktualnog ovlaštenja za vožnju
- Izdavanje naredbe prema nadležnim signalno – sigurnosnim uređajima o postavljanju puta vožnje za vlak u za to pogodnom trenutku
- Rješavanje konflikata između međusobno suprotstavljenih putova vožnji

Sustav za automatsko postavljanje putova vožnje odabire i postavlja putove vožnje za svaki vlak prije nailaska na mjesto početka zaustavnog puta do kraja aktualnog ovlaštenja za vožnju, koje najčešće predstavlja skretnicu ili dio pruge na kojem vlak može promijeniti smjer svoga kretanja. Sustav za automatsko postavljanje putova vožnje može odabirati put vožnje temeljeno na voznom redu, a sofisticiraniji sustavi automatski mijenjaju put vožnje kada se pojavi neki zastoj ili poteškoća na prethodno planiranom putu vožnje. [15]

Izdavanje naredbe prema nadležnim signalno – sigurnosnim uređajima vrši se kada vlak prilazi signalu, tj. približava se daljini vidljivosti signala. Najčešće je vrijeme postavljanja putova vožnje ovisno o voznom redu, ali ponekad vlakovi ne voze po predviđenom redu zbog raznih poteškoća u odvijanju željezničkog prometa. Također može doći i do ručnog unošenja novih putova vožnje, koje nisu planirane voznim redom. Zbog toga sustav za automatsko postavljanje putova vožnje, koristeći informacije o stvarnom položaju vlakova i raspoloživosti infrastrukture, mora izvršiti pravovremeno postavljanje putova vožnje i izdavanje naredbi prema nadležnim signalno – sigurnosnim uređajima. [15]

Vlakovi se mogu križati i mimoilaziti samo na određenim dijelovima pruge, kao što su kolodvori. To dovodi do pojave suprotstavljanja dvaju ili više putova vožnje. Kako bi se promet nastavio nesmetano odvijati, sustav za automatsko postavljanje putova vožnje mora riješiti takve konfliktne situacije davanjem prioriteta prolaska određenom vlaku.

Put vožnje predstavlja mjesto na pruzi koje se nalazi između dva signala i na kojem je dano dopuštenje za vožnju vlaka. Svi putovi vožnje na svom početku imaju signal, dok na svome završetku mogu imati signal ili prsobran ako se radi o slijepom kolosijeku. Informacije o dopuštenju za vožnju tim putem vožnje vlaku se daju na signalu koji predstavlja početak navedenog puta vožnje. [15] Primjer putova vožnje koje je moguće postaviti u jednom kolodvoru vidljiv je na Slici 11.



**Slika 11.** Primjeri putova vožnje vlaka kod automatskog postavljanja putova vožnje

Izvor: [15]

Na prikazu kolodvora i putova vožnje koji se u tom kolodvoru mogu postaviti vidljivo je da su neki putovi vožnje suprotstavljeni. Sustav automatskog postavljanja putova vožnje prije odabira puta vožnje i davanja dopuštenja vlaku za nastavak njegovog kretanja mora provjeriti ima li putova vožnje koji su suprotstavljeni putu vožnje koji se želi postaviti te da li su ti putovi vožnje postavljeni. Ako su suprotstavljeni putovi vožnje već postavljeni sustav automatskog postavljanja puta vožnje nije u mogućnosti postaviti željeni put vožnje i dati vlaku dopuštenje za vožnju te treba čekati da se suprotstavljeni put vožnje razriješi.




U praksi postoje dva različita principa po kojima se vrši automatsko postavljanje putova vožnje. Kod prvog principa postavljanje putova vožnje je unaprijed definirano zadanim redoslijedom i temeljeno je na unaprijed zadanom redoslijedu prometovanja vlakova. Kada se vlak približava mjestu na kojem mu se mora definirati put vožnje da bi nastavio nesmetano kretanje, sustav prema unaprijed definiranom redoslijedu postavlja taj put vožnje. Ovaj sustav najčešće se primjenjuje na prugama s manjim brojem vlakova, na kojima rijetko dolazi do promjena u redoslijedu prometovanja vlakova. U takvom slučaju do promjena u redoslijedu prometovanja vlakova najčešće dolazi zbog većih poteškoća koje se javljaju u izvršavanju voznoga reda, kao što su kvarovi na vozilima, izvanredni događaji ili drugi razlozi koji uzrokuju značajnija kašnjenja vlakova. Do promjene u redoslijedu vožnje vlakova također može doći uvođenjem novih trasa vlakova, koje nisu bile predviđene prilikom izrade planiranog voznog reda. U takvim situacijama dispečer može ručno promijeniti redoslijed postavljanja određenih putova vožnje, kako bi se osiguralo daljnje nesmetano odvijanje prometa. [1]

U drugom principu postavljanje putova vožnje vrši se prema identifikaciji broja vlaka. U ovom slučaju sustav za automatsko postavljanje putova vožnje raspolaže podacima o predviđenom voznom redu svih vlakova, kao i trenutnom položaju svih vlakova koji se nalaze na pruzi. Kada se primjerice određeni vlak približava daljini vidljivosti predsignala, koji će mu proslijediti informaciju o dopuštenju za daljnje nastavljanje kretanja prema kolodvorskom području, sustav za automatsko postavljanje putova vožnje provodi odabir ulaznog puta vožnje u kolodvor. Postavljanje putova vožnje u ovom principu optimalno je izvesti neposredno prije nego što vlak naiđe na daljinu vidljivosti predsignala, kako bi se osigurala daljnja nesmetana vožnja vlaka i kako se ne bi utjecalo na predviđeni režim vožnje. Kod ovakvog principa postavljanja putova vožnje, suprotstavljene putove vožnje moguće je riješiti na temelju dvije različite strategije. [1]

U prvoj strategiji putovi vožnje postavljaju se u skladu s planiranim slijedom prometovanja vlakova, koje je definirano voznim redom. U ovakvom načinu odabira puta vožnje sustav automatskog postavljanja putova vožnje mora raspolagati bazom podataka u kojoj se nalaze svi definirani putovi vožnje, kao i trase svih vlakova predviđenih voznim redom. U takvom načinu vlak kojem je voznim redom definirano da dobiva određeni put vožnje nakon nekog drugog vlaka, koji kasni u odnosu na predviđeni vozni red, čekat će da prvom vlaku bude dodijeljen put vožnje i da izvrši tu vožnju, a tek će mu onda biti dodijeljen njegov put vožnje. To predstavlja problem zbog toga što takvim načinom rješavanja suprotstavljenih putova vožnje dolazi do generiranja još većih kašnjenja vlakova na mreži, ukoliko samo jedan vlak kasni. U ovom slučaju dispečer mora izvesti korekcije voznog reda, kako bi se smanjilo kašnjenje vlakova i riješile situacije u kojima zbog suprotstavljenih putova vožnje dolazi do generiranja kašnjenja vlakova. [1]

U drugoj strategiji postavljanje putova vožnje vrši se na temelju položaja vlakova. U toj strategiji ne uzima se u obzir redoslijed prometovanja vlakova, koji je predviđen voznim redom. Baza podataka na temelju koje se vrši odabir odgovarajućeg puta vožnje mora sadržavati podatke o putovima vožnje za svaki vlak u sklopu njegovog opisa. Kada prilikom prometovanja vlakova dođe do potrebe postavljanja putova vožnje za dva vlaka kojima su ti putevi vožnje suprotstavljeni, sustav mora određenom vlaku dati prioritet za postavljanje njegovog puta vožnje. Navedeno davanje prioriteta mora se dodijeliti prije nego što vlak dođe do točke postavljanja puta vožnje koji je suprotstavljen s putom vožnje drugog vlaka. Kako bi sustav uspješno mogao postavljati putove vožnje i rješavati konflikte prilikom postavljanja putova vožnji, svi vlakovi moraju biti registrirani od strane toga sustava prije nego što dođu do točke nailaska za automatsko postavljanje putova vožnje. To se može postići virtualnom rezervacijom putova vožnje, koji se nalaze na određenoj udaljenosti od trenutno zauzetog prostornog odsjeka. Takvom virtualnom rezervacijom putova vožnje otkrivaju se suprotstavljeni putovi vožnje koje je potrebno postaviti te sustav na temelju određenih prioriteta može odrediti kojem će vlaku dati prednost prolaska. [1]

Primjer virtualne rezervacije suprotstavljenih putova vožnje vidljiv je na Slici 12. Na toj slici također je vidljivo i naznačeno mjesto preklapanja dva suprotstavljena puta vožnje. Na navedenom primjeru putovi vožnje su suprotstavljeni na središnjem dijelu.



**Slika 12.** Virtualna rezervacija putova vožnje

Izvor: [1]


Prilikom određivanja prioriteta postavljanja puta vožnje, u slučaju suprotstavljenih putova vožnje, u obzir je moguće uzeti velik broj različitih parametara. Najčešće korišteni parametar je rang vlaka te se u velikom broju slučajeva vlakovima višeg ranga daje prednost postavljanja puta vožnje. Osim ranga vlaka, prilikom davanja prioriteta mogu se uzeti u obzir i popunjenost vlaka, kašnjenje vlaka, utjecaj kašnjenja vlaka na druge vlakove, težina teretnih vlakova i potrošnja energije, te velik broj drugih parametara pomoću kojih bi se moglo omogućiti bolje vršenje automatskog postavljanja putova vožnje, koje bi moglo utjecati na efikasnije i ekonomičnije odvijanje željezničkog prometa.

Upravo u postupku rješavanja suprotstavljenih putova vožnje, kao i rješavanju drugih problema prilikom vršenja automatskog postavljanja putova vožnje, koji se javljaju kašnjenjem vlakova i značajnijim odstupanjima od planiranog voznog reda, dolazi do mogućnosti upotrebljavanja inteligentnih transportnih sustava. Ti sustavi imaju mogućnost donošenja određenih odluka umjesto dispečera, što dovodi do značajnog smanjenja njegovog radnog opterećenja. Primjer novog modela takvog sustava, koji primjenom neizrazite logike na temelju različitih parametara vrši rješavanje problema davanja prioriteta vlaku prilikom suprotstavljenih putova vožnje dvaju vlakova, prikazan je u nastavku ovog rada.

#### 4. IZRADA NOVOG MODELA SUSTAVA PODRŠKE PRI REGULACIJI ŽELJEZNIČKOG PROMETA TEMELJENOG NA NEIZRAZITOJ LOGICI

Zbog kompleksnosti dispečerovog posla te velikog radnog opterećenja dolazi do potrebe razvoja ekspertnih sustava čija je svrha pružanje podrške dispečeru u izvršavanju određenih zadataka koji su pred njega stavljeni. Takvi sustavi moraju imati mogućnost rješavanja određenih problema umjesto dispečera te prikaza rješenja tih problema, koje dispečer zatim prihvaća i provodi. Daljnji razvoj ekspertnih sustava omogućio bi potpunu zamjenu dispečera u izvršavanju određenih zadataka. Najveća mogućnost primjene navedenih ekspertnih sustava je u rješavanju problema koji se javljaju prilikom upravljanja željezničkim prometom. Jedan od tih problema je rješavanje suprotstavljenih putova vožnje, tj. davanje prednosti postavljanja puta vožnje, a time i prolaska, jednom vlaku u odnosu na drugi. Takav sustav zamijenio bi dispečera koji na temelju različitih parametara daje prednost postavljanja putova vožnje. Za izradu ekspertnog sustava koji vrši navedenu funkciju i ima sposobnost rješavanja problema primjenom zakonitosti ljudskog razmišljanja, potrebno je primijeniti neizrazitu logiku.

U ovom radu predstavljen je novi model sustava podrške pri regulaciji željezničkog prometa temeljenog na neizrazitoj logici. Predstavljani model na temelju različitih parametara rješava problem davanja prednosti prolaska određenom vlaku ukoliko dva vlaka imaju suprotstavljene putove vožnje. Primjer takve prometne situacije, u kojoj dolazi do suprotstavljanja putova vožnje dvaju vlakova, vidljiv je na Slici 13.



**Slika 13.** Primjer suprotstavljenih putova vožnje

Izvor: [16]

Na Slici 13. mogu se vidjeti dva vlaka koja istovremeno prilaze istom kolodvoru. Zbog rasporeda kolodvorskih kolosijeka te putova pretrčavanja, nije moguće istovremeno postaviti putove vožnje za oba vlaka te im omogućiti ulazak u kolodvor. Zbog toga dolazi do potrebe davanja prednosti postavljanja puta vožnje jednom od prikazanih vlakova te mu omogućiti ulazak u kolodvor bez zaustavljanja na ulaznom signalu. Drugi vlak, kojem se ne daje prednost prolaska, mora stati ispred ulaznog signala i čekati da vlak s prednošću prolaska uđe u kolodvor te se u njemu sigurno zaustavi ispred izlaznog signala. Tek nakon toga vlak koji nije dobio prednost prolaska može nastaviti svoje putovanje i ulazak u prikazani kolodvor. Na Slici 13. vlaku broj 1 daje se prednost prolaska u odnosu na vlak broj 2. To je moguće zaključiti iz signalnih znakova koje prikazuju predsignali i ulazni signali prikazanog kolodvora. Zelenom i žutom bojom prikazan je postavljeni put vožnje za vlak broj 1.

Prikazana prometna situacija zahtijeva pravovremenu reakciju dispečera, koji na temelju određenih parametara mora odrediti kojem vlaku dati prednost. Radi smanjenja radnog opterećenja dispečera moguće je zadatak određivanja prioriteta kod suprotstavljenih putova vožnje izvršavati automatski, uz pomoć ekspertnih sustava. U ovom radu napravljen je model ekspertnog sustava u programu Matlab, koji se temelji na zakonitostima neizrazite logike.

Model sustava podrške pri regulaciji željezničkog prometa, čija je funkcija davanje prioriteta kod suprotstavljenih putova vožnje, rađen je u programu Matlab. Model je rađen u Mamdani sustavu neizrazitog logičkog zaključivanja. Kao što je već u poglavlju 2.1. ovog rada navedeno, svrha Mamdani sustava je omogućiti uporabu zakonitosti ljudskog načina razmišljanja u računalnom programu. Model sustava podrške pri regulaciji prometa rađen je kako bi se omogućilo smanjenje radnog opterećenja dispečera, a time i smanjenje mogućnosti njegovih pogrešaka koje mogu imati negativne rezultate na nesmetano odvijanje željezničkog prometa. U modelu se koriste zakonitosti pomoću kojih se dodjeljuje prioritet vlaku, a koje koristi dispečer prilikom rješavanja navedenog problema. Zakonitosti se temelje na razmatranju određenog broja parametara vlakova, pomoću kojih se određuje kojem vlaku treba dodijeliti prednost. Radi uspješnog djelovanja sustava potrebno je pažljivo odrediti koji parametri vlakova su najbitniji za određivanje njihovog prioriteta te po kojim zakonitostima se ti parametri vrednuju. U neizrazitom logičkom sustavu parametri pomoću kojih se vrednuju vlakovi izraženi su ulaznim i izlaznim varijablama, a zakonitosti po kojima se vlakovi vrednuju izraženi su IF – THEN pravilima.

Izrada sustava podrške pri regulaciji prometa može se podijeliti u dva osnovna koraka, a to su definiranje ulaznih i izlaznih varijabli sustava, te stvaranje pravila.

#### 4.1. Definiranje ulaznih i izlaznih varijabli sustava

Prvi korak prilikom izrade sustava neizrazitog zaključivanja u programu Matlab je definiranje ulaznih i izlaznih varijabli. Pomoću ulaznih varijabli definiraju se parametri koji se uzimaju u obzir prilikom vršenja zaključivanja u sustavu neizrazitog zaključivanja, a izlaznim varijablama definiraju se željeni rezultati, tj. raspon željenih rezultata neizrazitog logičkog zaključivanja. Ulazne i izlazne varijable dodaju se pomoću opcije: Edit>Add Variable. Na Slici 14 vidljiv je prozor u programu Matlab u kojem se vrši dodavanje ulaznih i izlaznih varijabli. Osim dodavanja ulaznih i izlaznih varijabli, u ovom prozoru moguće je definirati pomoću kojih se matematičkih funkcija vrše metode I, ILI, implikacije, agregacije i defuzifikacije. Također je, u ovom prozoru programa Matlab, moguće mijenjati nazive ulaznih i izlaznih varijabli.

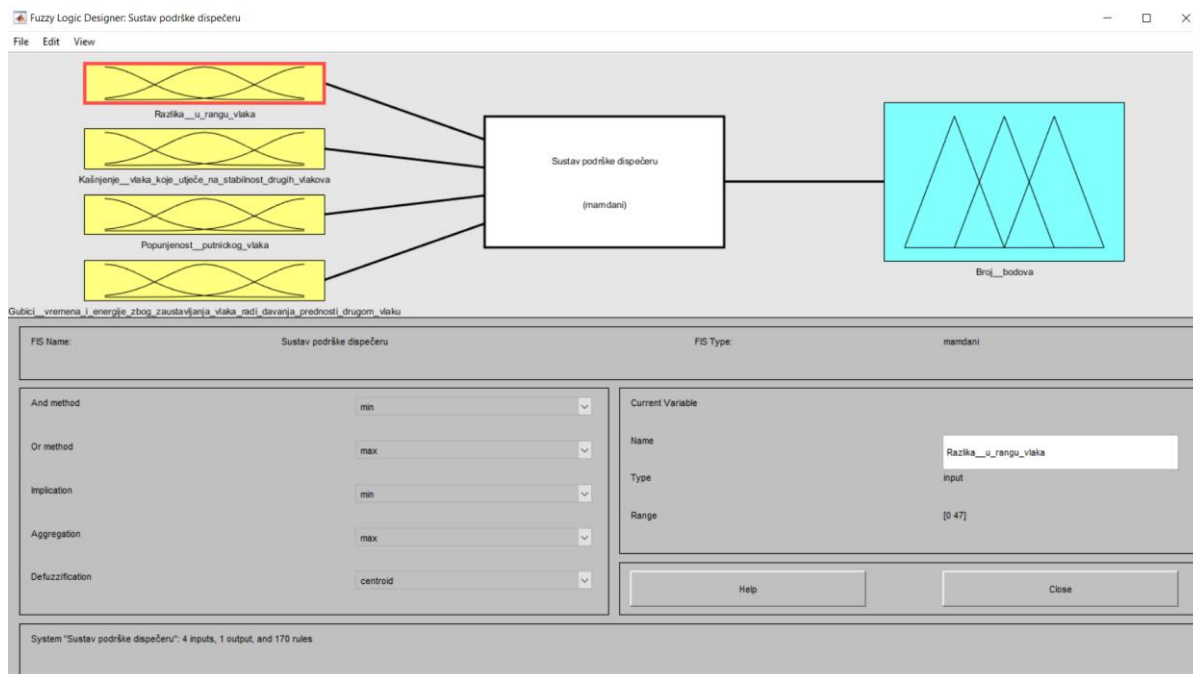
Definiranjem ulaznih i izlaznih varijabli daje se grubi oblik sustava neizrazitog zaključivanja, a te varijable moraju biti pomno odabrane uzimajući u obzir željenu svrhu sustava te željene rezultate koji se dobivaju na izlazu definiranog sustava. Ulazne i izlazne varijable nije moguće mijenjati nakon definiranja IF – THEN pravila.

Na Slici 14. vidljiv je prikaz ulaznih i izlaznih varijabli modela sustava za pružanje podrške dispečeru prilikom donošenja upravljačkih odluka. Za ulazne varijable uzeti su parametri koje dispečer uzima u obzir prilikom davanja prednosti određenom vlaku, ukoliko dođe do suprotstavljanja putova vožnje dvaju vlakova. Zbog potrebe za jednostavnošću sustava, u svrhu njegovog pravovremenog davanja željenih rezultata, izabrani su najbitniji parametri koje dispečer uzima u obzir prilikom davanja prednosti određenom vlaku.

Sustav neizrazitog zaključivanja za pružanje podrške pri upravljanju željezničkim prometom sastoji se od četiri ulazne varijable te jedne izlazne varijable. Ulazne varijable su:

- Razlika u rangi vlaka
- Kašnjenje vlaka koje utječe na stabilnost drugih vlakova
- Popunjenost putničkog vlaka
- Gubici vremena i energije zbog zaustavljanja vlaka radi davanja prednosti drugom vlaku

Za izlaznu varijablu uzet je broj bodova, pomoću kojih se dodjeljuje prednost postavljanja putova vožnje određenom vlaku. Sustav je osmišljen tako da se uzimaju u obzir parametri oba vlaka koja imaju suprotstavljene putove vožnje te se prednost prolaska daje vlaku koji ima veći broj bodova.



**Slika 14.** Definiranje ulaznih i izlaznih varijabli sustava podrške pri regulaciji željezničkog prometa

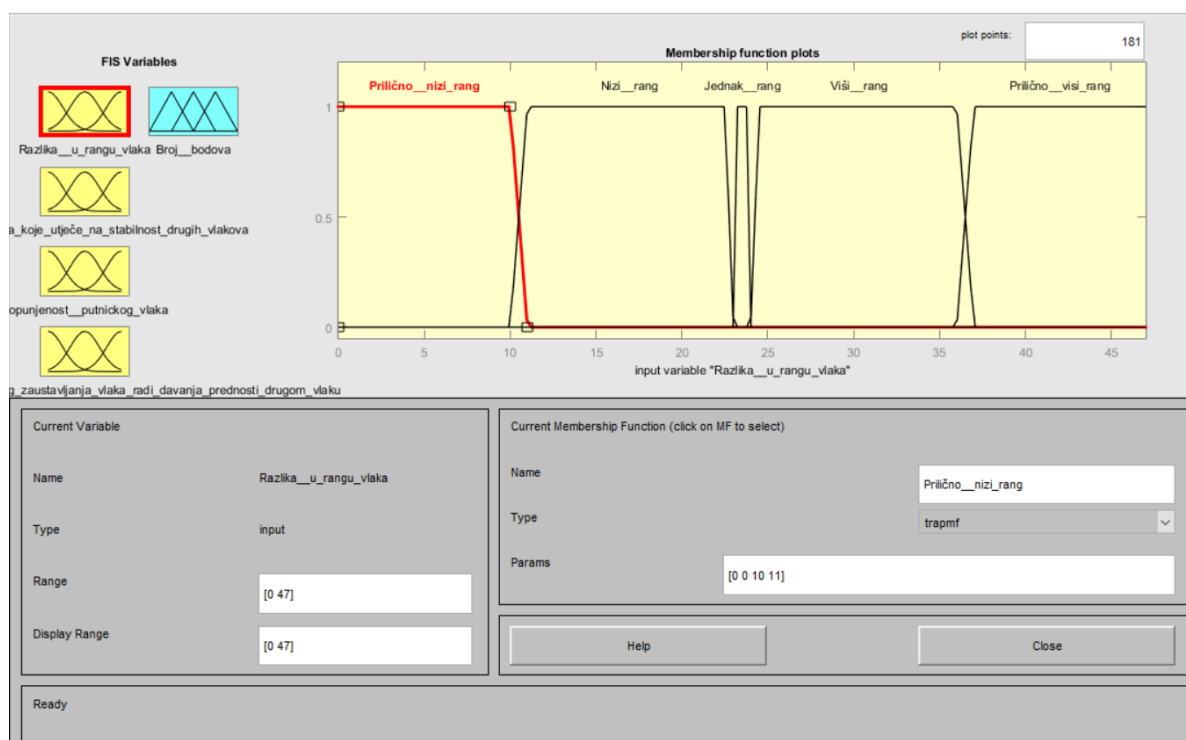
Nakon definiranja broja ulaznih i izlaznih varijabli, tim varijablama potrebno je odrediti raspon te ih podijeliti na određeni broj neizrazitih logičkih skupova definiranih funkcijama pripadnosti. Pomoću funkcija pripadnosti brojčanim vrijednostima, koje čine ulaz u sustav neizrazitog zaključivanja, određuje se stupanj pripadnosti određenom neizrazitom logičkom skupu. Dobro definiranje raspona ulaznih varijabli te optimalnog broja neizrazitih logičkih skupova, na koje su te varijable podijeljene, ključno je radi kasnijeg računanja tj. zaključivanja pomoću IF – THEN pravila.

Prozor u kojem se definira raspon ulaznih varijabli te u kojem ih se dijeli na određen broj neizrazitih logičkih skupova definiranih funkcijama pripadnosti vidljiv je na Slici 15. Kao što je već navedeno u ovom radu, funkcije pripadnosti neizrazitim logičkim skupovima mogu biti različitih oblika, koji se koriste ovisno o specifičnim potrebama sustava neizrazitog zaključivanja. U sustavu neizrazitog zaključivanja za pružanje podrške pri upravljanju željezničkim prometom koriste se funkcije pripadnosti u obliku trokuta (trimf) i u obliku trapeza (trapmf).

### 4.1.1. Razlika u rangu vlaka

Razlika u rangu vlaka je prva ulazna varijabla. U Hrvatskoj postoji 21 rang vlakova, a pošto vlakovi istog ranga iz vanjskog prometa imaju prednost pred vlakovima iz unutarnjeg prometa, može se reći da ukupno postoji 24 ranga vlakova. Zbog toga je raspon ulazne varijable razlike u rangovima od 0 do 47. Taj raspon podijeljen je na pet neizrazitih logičkih skupova definiranih funkcijama pripadnosti. Ti neizraziti logički skupovi predstavljaju stupnjeve razlike u rangovima vlakova. Tako rang vlaka može biti: prilično niži, niži, jednak, veći i prilično veći u odnosu na rang drugog promatranog vlaka. Navedenu ulaznu varijablu razlike u rangovima vlakova te njene neizrazite logičke skupove moguće je vidjeti na Slici 15.

Prilikom uspoređivanja dvaju vlakova, ukoliko dođe do suprotstavljanja njihovih putova vožnje, dispečer uvijek prvo gleda razliku u rangovima vlakova, tj. koji vlak ima viši rang. U velikom broju slučajeva prednost se daje vlaku s višim rangom. Međutim, zbog potrebe za neometanim odvijanjem željezničkog prometa te smanjenja kašnjenja vlakova na mreži, prednost se može dati i vlaku s nižim rangom, ukoliko taj vlak ima veliko kašnjenje koje može uzrokovati kašnjenje drugih vlakova na mreži te dovesti do značajnijih poteškoća u odvijanju željezničkog prometa. Osim navedenih parametara dispečer gleda i razne druge parametre prilikom donošenja odluke kojem će vlaku dati prednost prolaska. Najbitniji od tih parametara uključeni su u prikazani model sustava neizrazitog zaključivanja.



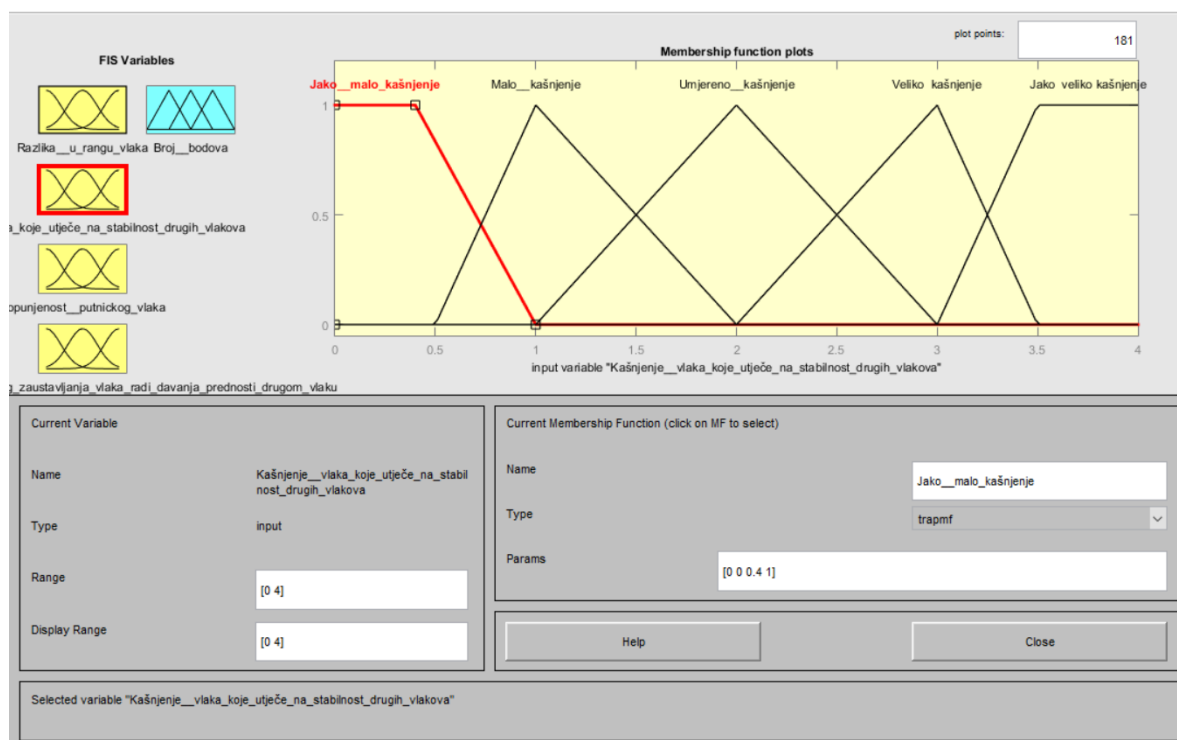
Slika 15. Ulazna varijabla: Razlika u rangovima vlakova



#### 4.1.2. Kašnjenje vlaka koje utječe na stabilnost drugih vlakova

Kašnjenje vlaka druga je ulazna varijabla u prikazanom modelu sustava neizrazitog zaključivanja. Kao što je već navedeno, prilikom donošenja odluke kojem vlaku dati prednost prolaska ključno je uzeti u obzir parametar kašnjenja vlaka. Taj parametar je izrazito bitan zbog kompleksnosti željezničke mreže i upravljanja prometom na toj mreži. Naime, kašnjenje jednog vlaka može prouzročiti kašnjenje drugih vlakova, koje se dalje akumulira i može prouzročiti značajnije poteškoće u nesmetanom odvijanju željezničkog prometa.

Ulazna varijabla kašnjenja vlaka koje utječe na stabilnost drugih vlakova ima raspon od 0 do 4. Taj broj predstavlja kašnjenje vlaka, koji se približava kolodvoru te kojemu treba dati ili oduzeti prednost prolaska, izraženo u minutama. Navedena ulazna varijabla podijeljena je na pet neizrazitih logičkih skupova definiranih funkcijama pripadnosti. Tako vlak može imati jako malo kašnjenje (0-1 min.), malo kašnjenje (0.5-2 min.), umjereno kašnjenje (1-3 min.), veliko kašnjenje (2-3.5 min.), te jako veliko kašnjenje (3-4 min.). Sva kašnjenja veća od četiri minute pridjeljuju se neizrazitom logičkom skupu jako velikog kašnjenja vlaka s pripadnošću 1. Pomoću navedenih funkcija pripadnosti ulaznoj vrijednosti kašnjenja vlaka određuje se stupanj pripadnosti određenim neizrazitim logičkim skupovima ulazne varijable. Ulazna vrijednost kašnjenja može pripadati jednom ili dva neizrazita logička skupa s određenim stupnjem pripadnosti. Za podjelu raspona ulazne varijable kašnjenja vlaka korištene su funkcije pripadnosti u obliku trokuta i trapeza. Navedena ulazna varijabla s njenim neizrazitim logičkim skupovima prikazana je na Slici 16.



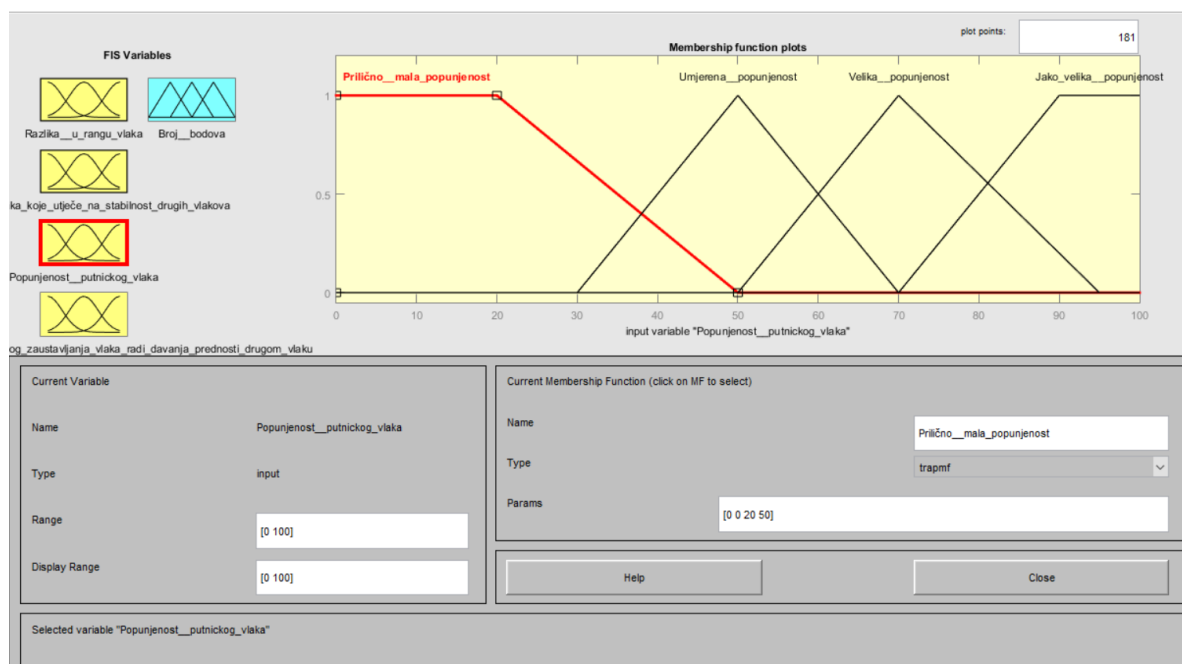
**Slika 16.** Ulazna varijabla: Kašnjenje vlaka koje utječe na stabilnost drugih vlakova

### 4.1.3. Popunjenost putničkog vlaka

U modernom upravljanju željezničkim prometom od ključnog je značaja točnost prometovanja vlakova. Ta potreba za točnosti je puno izraženija kod putničkih vlakova, koji su značajno osjetljiviji na kašnjenje od teretnih vlakova. Kašnjenje od samo par minuta može značajno utjecati na zadovoljstvo putnika, što može dovesti do smanjenja njihovog broja. Zbog toga, u modernom upravljanju željezničkim prometom, dispečer mora uzeti u obzir i parametar popunjenosti putničkog vlaka prilikom donošenja odluke o davanju prednosti prolaska određenom vlaku. Naime ukoliko dispečer oduzme prednost putničkom vlaku velike popunjenosti, koji već ima određeno kašnjenje, to može uzrokovati još veće kašnjenje tog vlaka što dovodi do nezadovoljstva putnika. Zbog toga je popunjenost putničkog vlaka jedna od ulaznih varijabli prikazanog modela sustava neizrazitog zaključivanja.

Ulazna varijabla popunjenosti putničkog vlaka ima raspon od 0 do 100, što predstavlja popunjenost vlaka od 0 do 100%. Popunjenost se može pratiti pomoću senzora na vratima vlaka, koji bilježe putnike koji ulaze i izlaze iz vlaka. Broj putnika se zatim uspoređuje s maksimalnim brojem putnika koji se mogu nalaziti u vlaku te se tako dobiva uvid u trenutnu popunjenost određenog putničkog vlaka na mreži.

Navedena ulazna varijabla podijeljena je na četiri neizrazita logička skupa, kojima se definira stupanj popunjenosti vlaka. Tako su definirani skupovi prilično male, umjerene, velike te jako velike popunjenosti putničkog vlaka. Radi pojednostavljenja sustava, ukoliko je promatrani vlak teretni, takva se situacija poistovjećuje s malom popunjenošću vlaka. Navedena ulazna varijabla vidljiva je na Slici 17.



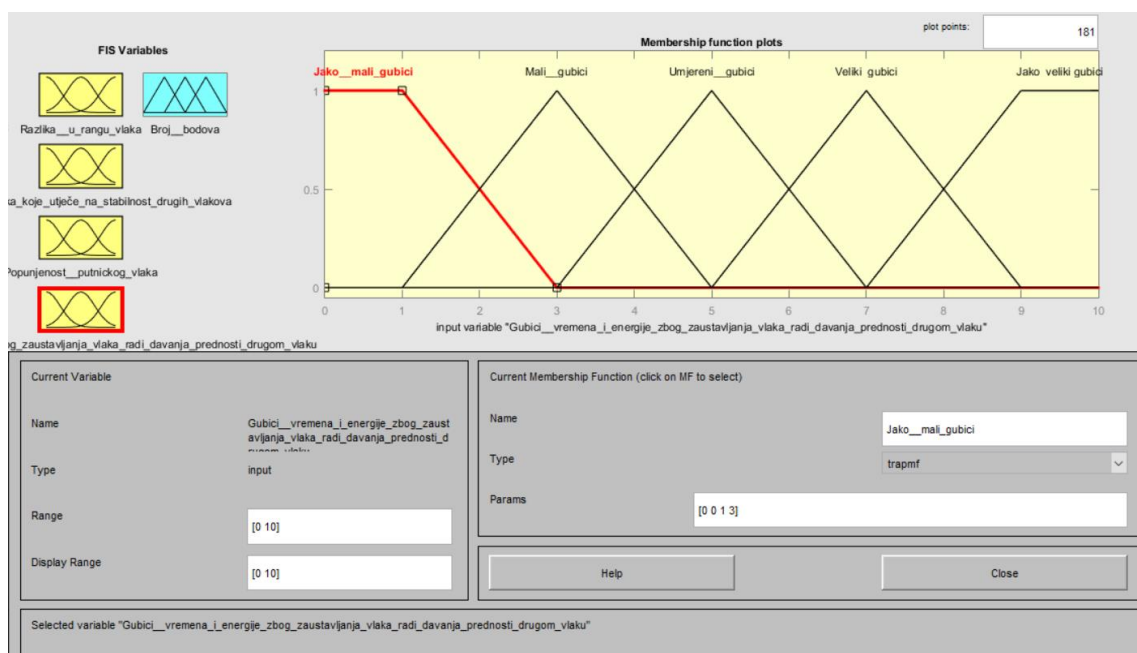
**Slika 17.** Ulazna varijabla: Popunjenost putničkog vlaka

#### 4.1.4. Gubici vremena i energije zbog zaustavljanja vlaka radi davanja prednosti drugom vlaku

U modernom upravljanju željezničkim prometom, između ostalog, velika pozornost pridaje se i ekonomičnosti vlakova te se teži smanjenju potrošnje energije koju vlakovi troše. Zbog toga, dispečer prilikom upravljanja prometom treba uzeti u obzir i taj parametar, što potencijalno može dovesti do značajnije uštede energije za pogon vlakova.

Zbog navedenog u promatranom modelu sustava neizrazitog zaključivanja, jedna od ulaznih varijabli su gubitci vremena i energije zbog zaustavljanja vlaka radi davanja prednosti drugom vlaku. Taj parametar najviše je izražen prilikom oduzimanja prednosti teškom teretnom vlaku koji prilazi kolodvoru punom brzinom. Zbog oduzimanja prednosti taj vlak treba se zaustaviti na ulaznom signalu, pričekati da vlak iz suprotnog smjera uđe u kolodvor i zaustavi se ispred izlaznog signala, te tek onda nastaviti putovanje prema kolodvoru. Radi toga dolazi do značajno veće potrošnje energije za pogon vlaka, pošto on mora iz pune brzine potpuno stati na ulaznom signalu, pa tek onda nastaviti putovanje. Osim povećanja potrošnje energije u tom slučaju dolazi i do značajnijih vremenskih gubitaka. Iako je parametar gubitka vremena i energije najizraženiji za teške teretne vlakove u punoj brzini, on može u određenim slučajevima biti prisutan i kod putničkih vlakova.

U promatranom sustavu neizrazitog zaključivanja ulazna varijabla gubitaka vremena i energije ima raspon od 0 do 10. Taj raspon predstavlja ljestvicu gubitaka vremena i energije od jako malih do jako velikih gubitaka. Broj na ljestvici gubitaka vremena i energije dobiva se iz parametara brzine te mase promatranog vlaka. Raspon navedene ulazne varijable podijeljen je na pet neizrazitih logičkih skupova. Navedena ulazna varijabla vidljiva je na Slici 18.



**Slika 18.** Ulazna varijabla: Gubici vremena i energije zbog zaustavljanja vlaka

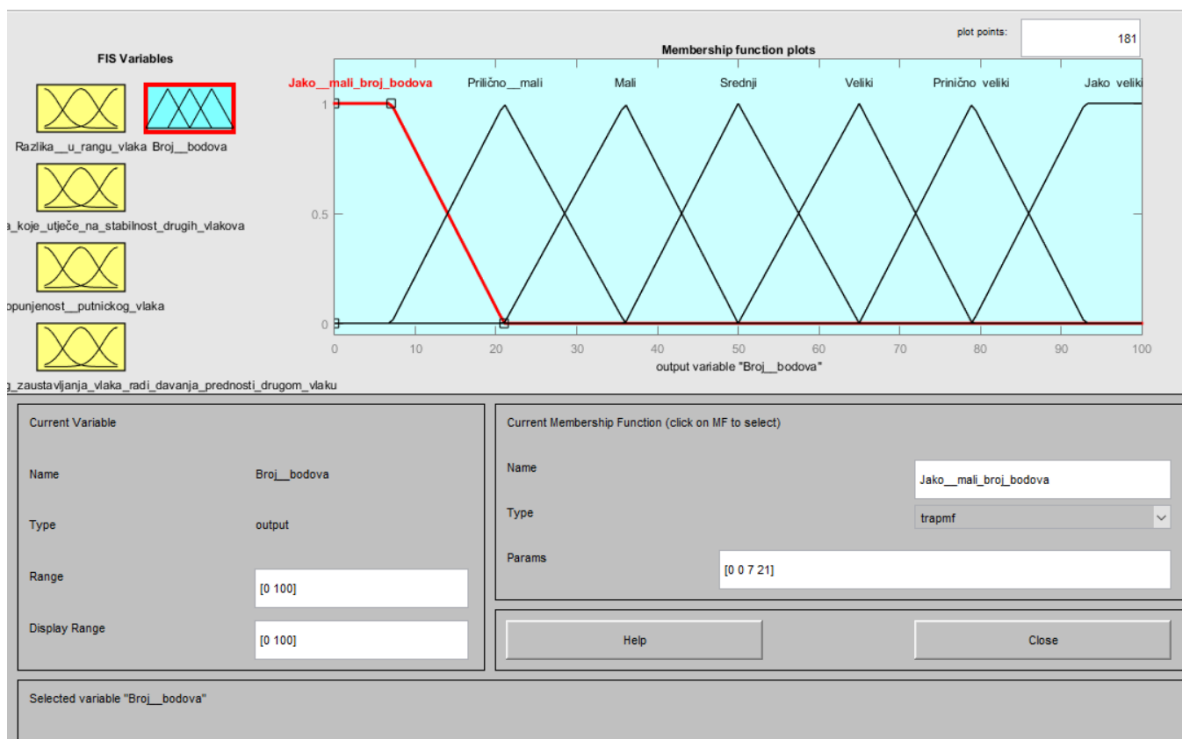
#### 4.1.5. Broj bodova

Sustav neizrazitog zaključivanja za pružanje podrške pri regulaciji željezničkog prometa konstruiran je s jednom izlaznom varijablom, brojem bodova. Navedena izlazna varijabla dobiva se primjenom zaključivanja u neizrazitom logičkom sustavu, koje je definirano IF – THEN pravilima.

Izlazna varijabla broja bodova ima raspon od 0 do 100, što predstavlja ljestvicu bodovanja na temelju koje se daje ili oduzima prednost prolaska promatranom vlaku. Raspon navedene izlazne varijable podijeljen je na sedam neizrazitih logičkih skupova. Ti skupovi predstavljaju podjelu raspona broja bodova koji može biti jako mali, prilično mali, mali, srednji, veliki, prilično veliki te jako veliki. Raspon navedene izlazne varijable podijeljen je na veći broj neizrazitih logičkih skupova od raspona ulaznih varijabli kako bi se moglo bolje definirati bodovanje prilikom izrade IF – THEN pravila te povećala preciznost sustava bodovanja.

Sustav bodovanja konstruiran je tako da se u sustav neizrazitog zaključivanja za pružanje podrške pri upravljanju prometom unose parametri oba vlaka koji se uspoređuju radi davanja prednosti te se prednost daje vlaku s većim brojem bodova.

Navedena izlazna varijabla, s njenim rasponom i neizrazitim logičkim skupovima vidljiva je na Slici 19.



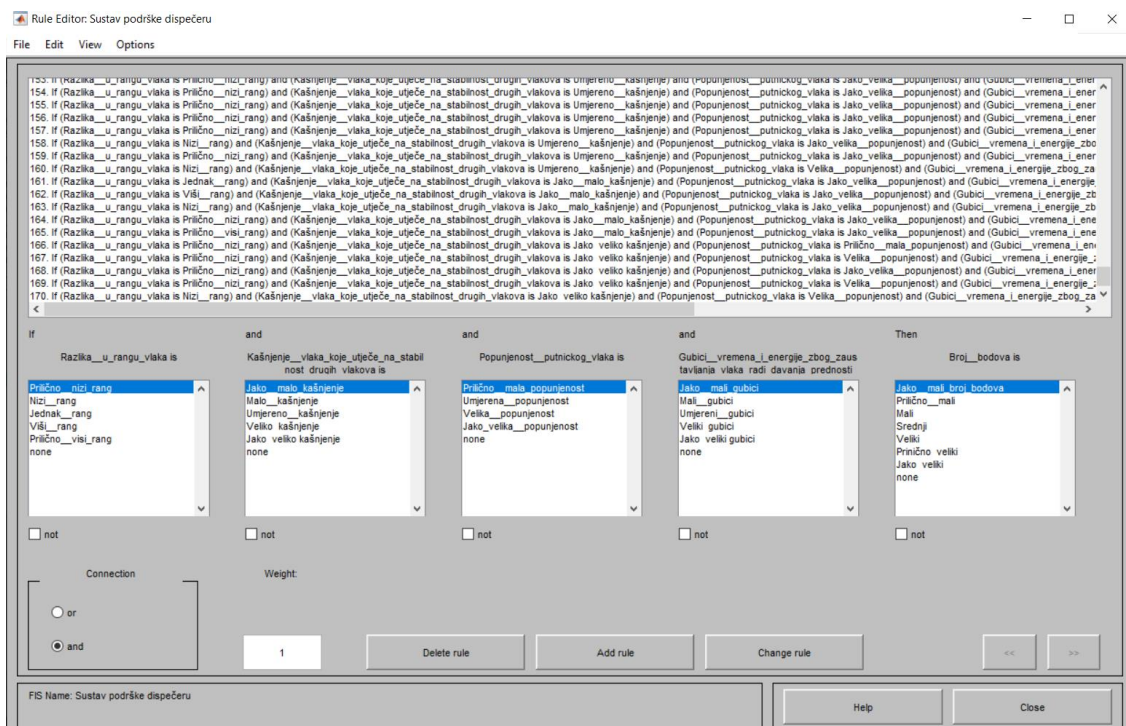
Slika 19. Izlazna varijabla: Broj bodova

## 4.2. Izrada i pregled pravila sustava podrške pri regulaciji željezničkog prometa

Nakon definiranja ulaznih i izlaznih varijabli potrebno je izraditi pravila na temelju kojih će neizraziti logički sustava vršiti zaključivanje. Prozor za izradu te uređivanje pravila vidljiv je na Slici 20. Do prozora za uređivanje pravila moguće je doći pomoću opcije Edit>Rules. U navedenom prozoru nude se opcije koje omogućuju dodavanje, uređivanje te brisanje pravila. Također se nudi odabir operatora kojim se povezuje prethodnik pravila. Moguće je izabrati povezivanje prethodnika pravila operatorom I (AND) ili ILI (OR). Također je moguće vršiti operaciju NE (NOT) na određeni dio prethodnika pravila. Svakom pravilu moguće je dati određenu težinu, od 0 do 1. Težina pravila ukazuje na stupanj istinitosti svakog pravila te svaka težina ispod 1 utječe na prethodnik pravila, kao i na samo pravilo.

Prethodnik pravila sastavljen je od vrijednosti funkcija pripadnosti neizrazitih logičkih skupova svih ulaznih varijabli. Te vrijednosti utječu na zaključak pravila. Proces stvaranja pravila temelji se na stvaranju različitih kombinacija funkcija pripadnosti neizrazitih logičkih skupova ulaznih varijabli, koje različito utječu na zaključak pravila i njegove funkcije pripadnosti. Prilikom izrade pravila posebnu pozornost treba posvetiti tome da pravila ne budu proturječna jer to dovodi do nestabilnosti sustava zaključivanja. Preciznost sustava neizrazitog zaključivanja povećava se s brojem pravila.

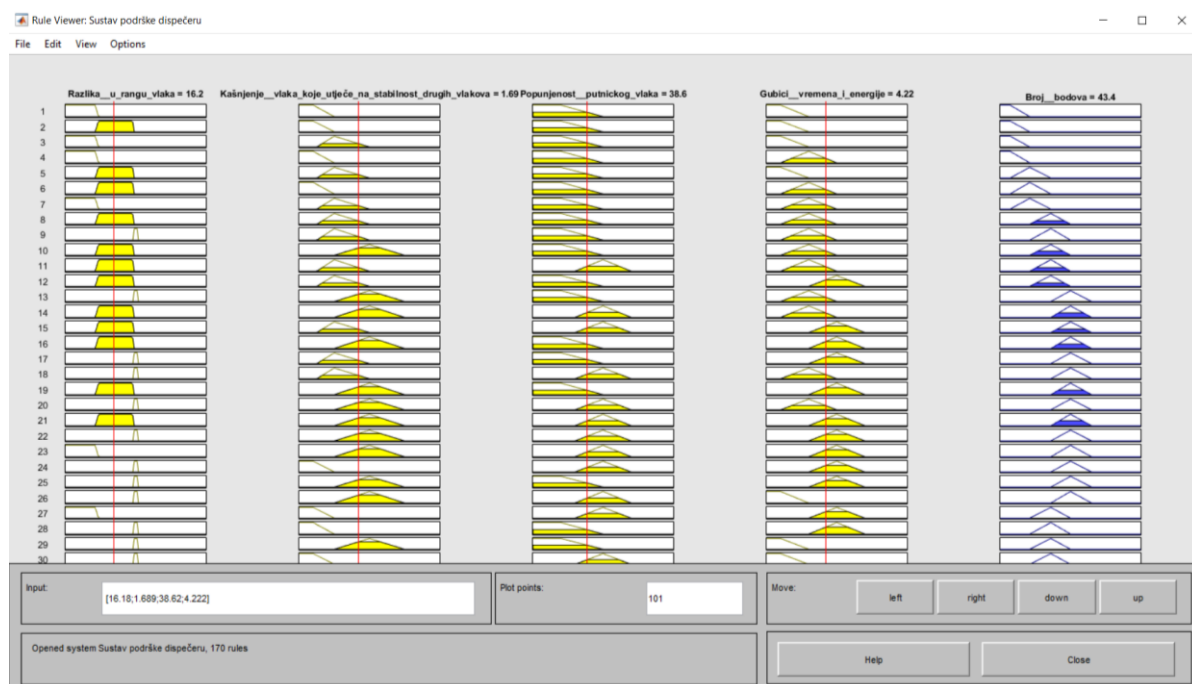
Na Slici 20 vidljiva su pravila modela sustava za pružanje podrške pri upravljanju željezničkim prometom. Prikazani sustav sastoji se od ukupno 170 pravila.



Slika 20. Definiranje pravila

Nakon definiranja pravila, djelovanje pravila moguće je provjeriti u za to predviđenom prozoru programa Matlab. Do prozora za provjeru pravila moguće je doći pomoću opcija View>Rules. U navedenom prozoru moguće je provjeriti djelovanje svih definiranih pravila unošenjem ulaznih vrijednosti za svaku ulaznu varijablu te provjerom da li određeno pravilo daje željenu izlaznu vrijednost. Ulazne vrijednosti moguće je prilagođavati ručno, pomoću crvene crte koja se nalazi kod svake ulazne varijable ili preko polja koje je predviđeno za unos brojčanih ulaznih vrijednosti. Ako se uoči da određeno pravilo ne daje željeni rezultat, pravilo je moguće promijeniti u prozoru programa Matlab prikazanog na Slici 20.

Opisani prozor za provjeru definiranih pravila u programu Matlab, s pravilima sustava neizrazitog zaključivanja za pružanje podrške pri upravljanju željezničkim prometom, vidljiv je na Slici 21. U prozoru su grafički prikazana pravila te funkcije pripadnosti neizrazitih logičkih skupova koje ta pravila obuhvaćaju. Različitim ulaznim vrijednostima, koje se mogu postaviti u ovom prozoru, pridjeljuje se stupanju pripadnosti različitih funkcija pripadnosti te se aktiviraju različita pravila koja definiraju izlazne vrijednosti. Funkcije pripadnosti koje su obuhvaćene unesenom vrijednošću na svakom ulazu označene su žutom bojom. Ovisno o stupnju pripadnosti određenom neizrazitom logičkom skupu, grafički prikazi funkcija pripadnosti u različitom su postotku popunjeni žutom bojom. Neizraziti logički skupovi izlazne varijable, tj. njihove funkcije pripadnosti koje su obuhvaćene korištenim pravilima naznačene su plavom bojom. Iz funkcija pripadnosti izlazne vrijednosti, metodama agregacije i računanja pripadne čvrste vrijednosti dobiva se brojčana vrijednost izlazne varijable.

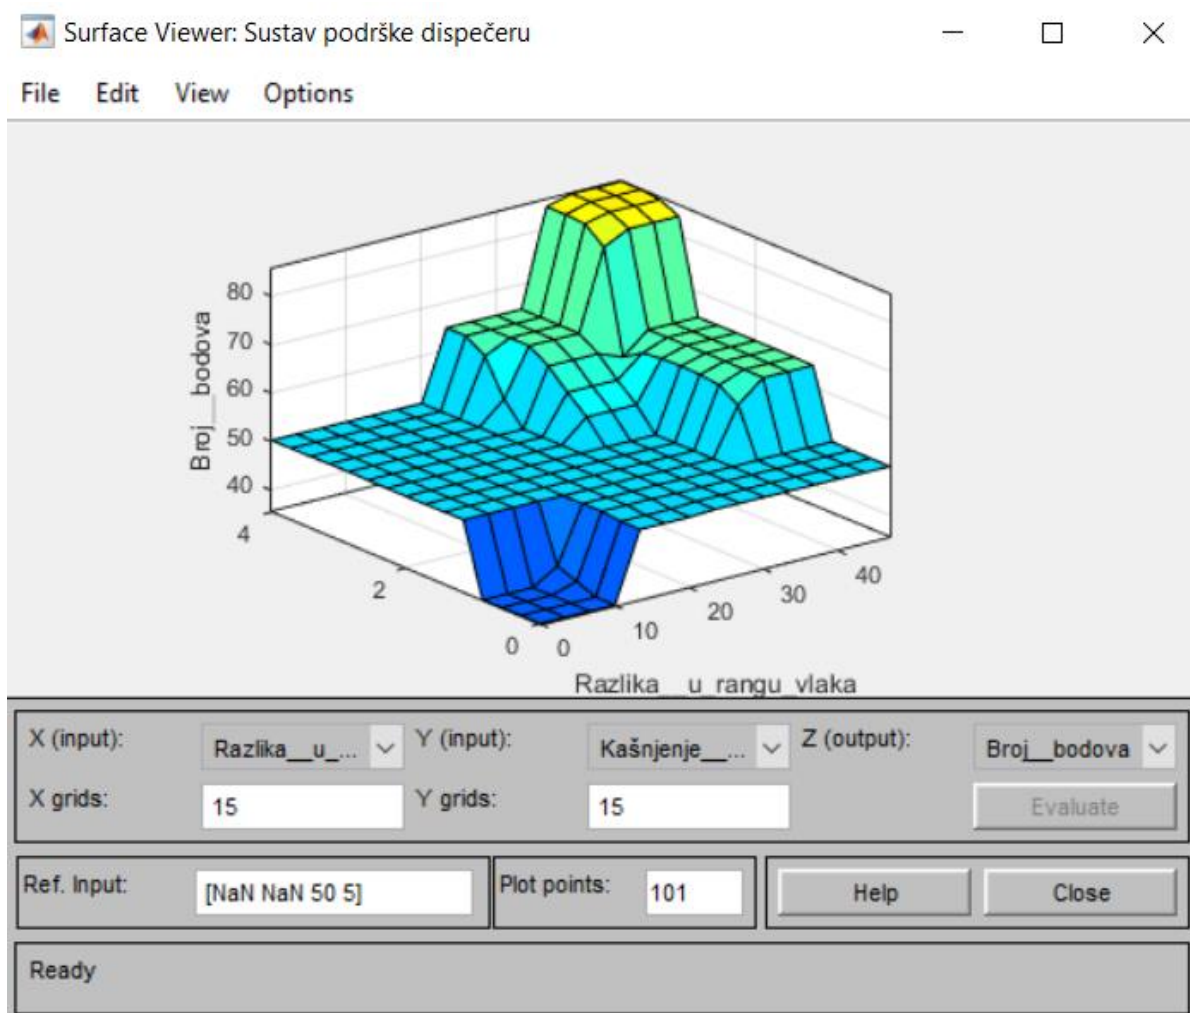


**Slika 21.** Prozor za provjeru definiranih pravila



Utjecaj pravila na međusobnu ovisnost ulaznih i izlaznih varijabli moguće je vidjeti pomoću grafičkog prikaza površine međuovisnosti. Površina međuovisnosti značajno se mijenja dodavanjem novih, ili promjenom već postavljenih pravila. Prozor programa Matlab u kojem je moguće vidjeti površinu međuovisnosti vidljiv je na Slici 22. Vidljivo je da je istovremeno grafički moguće prikazati međuovisnost dvaju ulaznih te jedne izlazne varijable. Pomoću izbornika moguće je izabirati varijable čija se međuovisnost trenutno prikazuje.

Na Slici 22 prikazana je međuovisnost dvaju ulaznih i jedne izlazne varijable sustava neizrazitog zaključivanja za pružanje podrške pri upravljanju željezničkim prometom. Ulazne varijable, čije se međuovisnost prikazuje su: razlika u rangu vlaka, te kašnjenje vlaka koje utječe na stabilnost drugih vlakova. Izlazna varijabla je broj bodova.

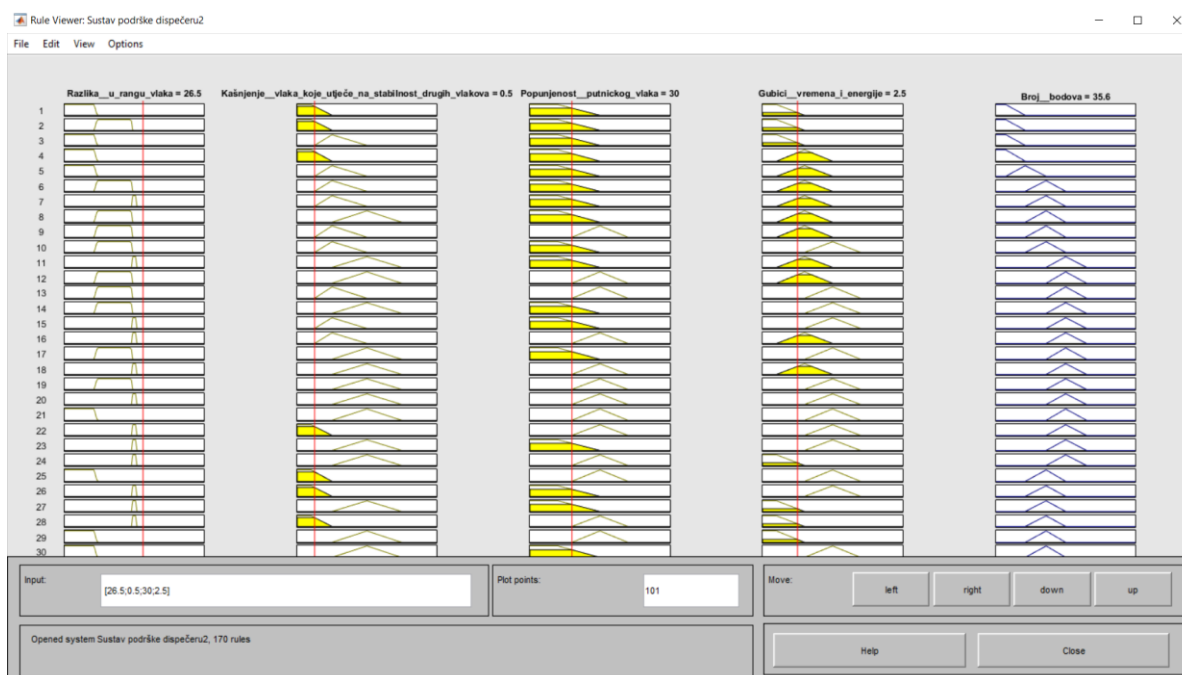


**Slika 22.** Prikaz površine međuovisnosti ulaznih i izlaznih varijabli sustava

### 4.3. Primjer korištenja novog modela sustava podrške pri regulaciji željezničkog prometa

Nakon izrade novog modela neizrazitog sustava, njegovo djelovanje moguće je provjeriti uzimanjem primjera suprotstavljenih vlakova s različitim parametrima. Ulazne vrijednosti sustava unose se u prozoru koji omogućuje pregled pravila i u kojem je ujedno moguće testiranje cjelokupnog sustava. Navedeni prozor programa matlab detaljno je opisan u poglavlju 4.2.

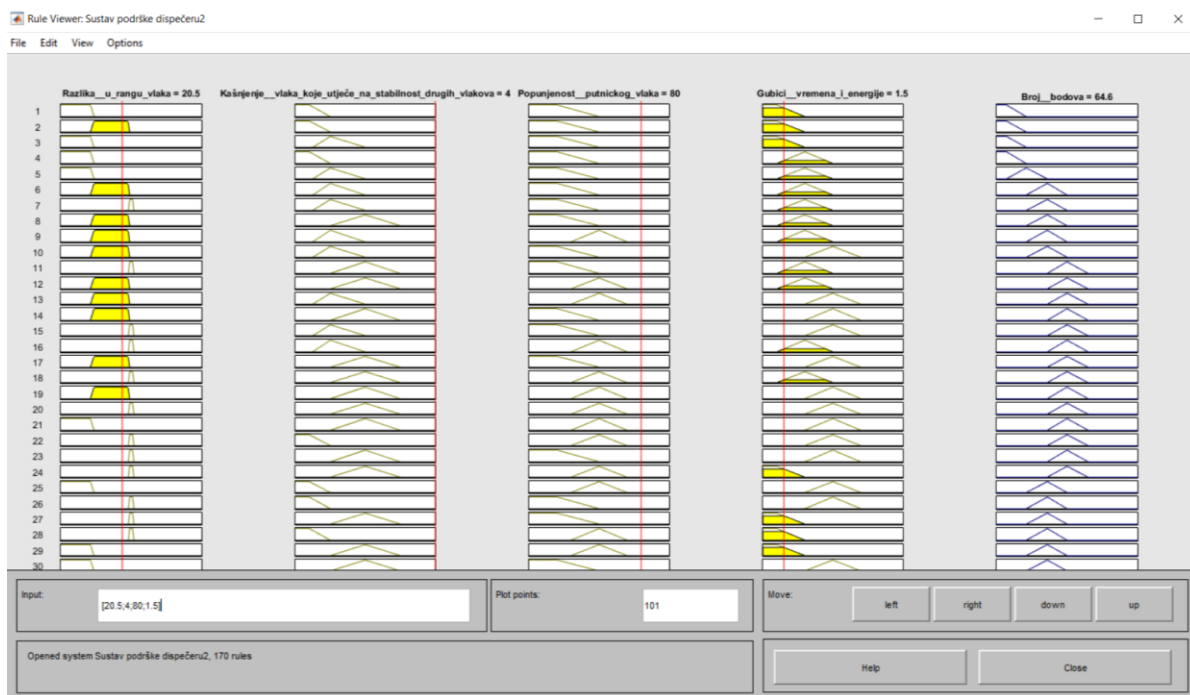
Za primjer korištenja modela neizrazitog logičkog sustava uzeta su dva putnička vlaka. Prvi vlak je ubrzani vlak s kašnjenjem od 0.5 minute, popunjenošću od 30 posto te gubitcima vremena i energije, ako se da prednost drugom vlaku, od 2.5. Nakon unosa ulaznih vrijednosti navedenom vlaku dodijeljeno je 35.6 bodova, što je vidljivo na Slici 23.



**Slika 23.** Broj bodova za ubrzani vlak u primjeru primjene modela sustava podrške

Drugi vlak u prikazanom primjeru je prigradski vlak koji ima kašnjenje od 4 minute, popunjenost od 80 posto te gubitke vremena i energije, ako se da prednost drugom vlaku, od 1.5. Nakon unosa ulaznih vrijednosti navedenom vlaku dodijeljeno je 64,6 bodova, što je vidljivo na Slici 24.





**Slika 24.** Broj bodova za prigradski vlak u primjeru primjene modela sustava podrške

Iz prikazanog primjera vidljivo je da je vlak nižeg ranga na temelju velikog kašnjenja i velike popunjenosti putnicima dobio prednost prolaska. Takvim načinom upravljanja prometom može se smanjiti kašnjenje navedenog vlaka te povećati zadovoljstvo putnika. Također, smanjenje kašnjenja navedenog vlaka dovodi i do smanjenja negativnog utjecaja koji taj vlak može imati na ostale vlakove na pružnoj mreži. Iz navedenog primjera vidljivo je kako sustav djeluje na način na koji je predviđen.


## **5. SIMULACIJSKA ANALIZA RADA SUSTAVA PODRŠKE PRI REGULACIJI ŽELJEZNIČKOG PROMETA**

Nakon konstrukcije novog modela sustava neizrazitog zaključivanja koji služi za pružanje podrške pri odlučivanju u procesu regulacije željezničkog prometa, navedeni model potrebno je ispitati u stvarnim prometnim situacijama u kojima dolazi do potrebe njegovog korištenja. U tu svrhu koristi se program OpenTrack koji služi za modeliranje prometne infrastrukture te simulaciju prometnih procesa koji se na toj infrastrukturi vrše.

U svrhu analiziranja rada novog modela sustava podrške u programu OpenTrack simulirane su prometne situacije u kojima dolazi do suprotstavljanja putova vožnje dvaju vlakova koji žele istovremenu ući u kolodvor. Do suprotstavljanja putova vožnje dolazi zbog sigurnosnih elemenata, tj. zbog putova pretrčavanja. U simuliranoj prometnoj situaciji vlakovi koji imaju suprotstavljene putove vožnje su različitih rangova te imaju različite karakteristike. Za pružanje rješenja kojem vlaku dati prioritet ulaska u kolodvor korišten je novi model sustava za pružanje podrške pri odlučivanju.

Željeznička infrastruktura na kojoj se simuliraju specifične prometne situacije sastoji se od jednog kolodvora te dva stajališta. Navedena infrastruktura nije uzeta iz stvarne mreže željezničke infrastrukture u Republici Hrvatskoj, nego je specifično modelirana u svrhu testiranja modela sustava podrške pri odlučivanju. Modelirani kolodvor sastoji se od tri kolosijeka. Svi kolosijeci su prijamno – otpremni te su opremljeni izlaznim signalima. Kolodvor također ima dva perona, tako da može primati putničke vlakove na sva tri navedena kolosijeka. Model pruge između stajališta i kolodvora opremljen je ulaznim signalima te predsignalima. Na modelu pruge, na daljini vidljivosti predsignala nalazi se mjerni instrument koji može u pripadajućoj tablici prikazati brzinu i vrijeme prolaska vlaka kroz određenu točku na pruzi. Navedena tablica služi za lakše praćenje kretanja vlakova prilikom simulacije te praćenje promjena u prometovanju vlakova nakon primjene različitih upravljačkih odluka. Navedeni model izrađene željezničke infrastrukture u programu OpenTrack prikazan je na Slici 25.

Za analiziranje novog modela sustava podrške uzeta su dva primjera suprotstavljanja putova vožnje vlakova s različitim parametrima. Prilikom obavljanja analize sustava, potrebno je unijeti parametre vlakova u sustav podrške u programu Matlab te odrediti koji vlak ima prioritet prolaska. Nakon toga, potrebno je navedeno rješenje sustava podrške u obliku upravljačke odluke uvesti u proces simulacije u programu OpenTrack te uočiti u kojoj mjeri ona utječe na odvijanje prometa. Navedeni utjecaj na odvijanje prometa može se vidjeti iz usporedbe prometne situacije u kojoj je uvedena upravljačka odluka, sa situacijom u kojoj ta odluka nije uvedena.



**Slika 25.** Model za analizu sustava podrške u programu OpenTrack

## 5.1. Prvi primjer analize rada sustava podrške pri regulaciji željezničkog prometa

Za prvi primjer uzeti su ubrzani i prigradski vlak. Ubrzani vlak ne kasni, ima popunjenost od 30 posto, te male do umjerene gubitke vremena i energije, ako se prednost da drugom vlaku. Prigradski vlak ima kašnjenje od 4 minute, popunjenost od 80 posto, te male do umjerene gubitke vremena i energije, ako se prednost da drugom vlaku. Nakon unošenja parametara vlakova u program Matlab, ubrzani vlak dobio je 35,6 bodova, dok je prigradski vlak dobio 71,6 bodova. Na temelju toga je zaključeno da prigradski vlak ima prednost prolaska.

Za analizu rada sustava u navedenom primjeru uzete su dvije opcije u kojima se poštuje i ne poštuje rješenje sustava podrške. Usporedbom te dvije opcije vidljiv je utjecaj koji rješenja sustava podrške imaju na odvijanje prometa.

Na Slici 26. vidljiva su vozna vremena za opciju upravljanja prometom u kojoj se ne provodi rješenje sustava podrške. Vidljivo je da prigradski vlak tijekom prometovanja nije smanjio kašnjenje od 4 minute, već je u kolodvoru dobio dodatnih 1 minutu i 36 sekundi kašnjenja. Ako se vrijeme stajanja prigradskog vlaka u kolodvoru smanji na 30 sekundi, kašnjenje vlaka pri izlasku iz kolodvora iznosilo bi 4 minute i 6 sekundi (navedeni primjer vidjeti u Prilogu 3).

Timetable

Course ID	Station	Track	Arrival	Departure	Use	Dwell	Stop	Delta Load	D
Prigradski	Stanica 2		HH:MM:SS HH:MM:SS	00:02:36 00:06:36	✓	0	-	0.000	
Prigradski	Kolodvor		00:06:05 00:11:41	00:08:05 00:13:41	✓	120	✓	0.000	
Prigradski	Stanica 1		HH:MM:SS HH:MM:SS	00:11:01 00:16:41	✓	0	-	0.000	
Ubrzani	Stanica 1		HH:MM:SS	00:06:36	✓	0	✓	0.000	
Ubrzani	Kolodvor		00:10:05 00:10:01	00:12:05 00:12:05	✓	120	✓	0.000	
Ubrzani	Stanica 2		HH:MM:SS HH:MM:SS	00:15:01 00:15:01	✓	0	-	0.000	

Add Rows Ins. Rows Del. Rows Function: Add Stops Dwell [s]: 60 Go

Course ID	Station	Type	Min. Wait	Max. Wait	Join	Split
-----------	---------	------	-----------	-----------	------	-------

Show Conn. Course Ins. Connection Del. Connection Show all Connections

Interval 2 Courses 6 Entries

Course ID: +2 Delta Time: + 01:00:00

☒ Keep Interval References  
☒ Keep Interval Ref. for Delays  
☐ Keep Interval Ref. for Conn.  
☒ Update Courses / Services

Create 1 Courses

Actual Course ID: Ubrzani Course

Ref. Course ID: Remove Show

Train: EuroCity

Train Speedtype: Putnicki

Train Category: Category 1

☒ Show Operations  
☒ Show Stationnames  
☐ Show Stops only  
☒ Show Track Name

☒ Show Day  
☒ Show act. Data Adjust  
☒ Show Delay Colors

☒ Show Use Departure Time  
☒ Show Delta Load  
☒ Show Distribution Name  
☒ Show Mean Delay

Delete Sync. Update Save DB Add Move Start Sort Show All Show

**Slika 26.** Vremena vožnje kod nepoštivanja rješenja sustava podrške za ubrzani i prigradski vlak

Na Slici 27. vidljiva su vozna vremena za opciju upravljanja prometom u kojoj se provodi rješenje sustava podrške. Osim provođenja rješenja sustava podrške izvršeno je i smanjenje vremena zadržavanja vlakova u kolodvoru. Vidljivo je da u kolodvoru dolazi do smanjenja kašnjenja prigradskog vlaka, dok ubrzani vlak ne generira značajnije kašnjenje. Primjer u kojem se provodi rješenje sustava podrške, ali se ne smanjuju vremena zadržavanja vlakova u kolodvoru vidljiv je u Prilogu 4.

Timetable

Course ID	Station	Track	Arrival	Departure	Use	Dwell	Stop	Delta Load	D
+ Prigradski	Stanica 2		HH:MM:SS	HH:MM:SS	00:02:36	00:06:36	✓	0	0.000
Prigradski	Kolodvor		00:06:05	00:10:01	00:08:05	00:10:38	✓	30	0.000
+ Prigradski	Stanica 1		HH:MM:SS	HH:MM:SS	00:11:01	00:13:34	✓	0	0.000
+ Ubrzani	Stanica 1		HH:MM:SS	HH:MM:SS	00:06:36	00:06:36	✓	0	0.000
Ubrzani	Kolodvor		00:10:05	00:11:41	00:12:05	00:12:11	✓	30	0.000
+ Ubrzani	Stanica 2		HH:MM:SS	HH:MM:SS	00:15:01	00:15:11	✓	0	0.000

Add Rows Ins. Rows Del. Rows Function: Add Stops Dwell [s]: 60 Go

Course ID	Station	Type	Min. Wait	Max. Wait	Join	Split
-----------	---------	------	-----------	-----------	------	-------

Show Conn. Course Ins. Connection Del. Connection Show all Connections

Interval 2 Courses 6 Entries

Course ID: + 2 Delta Time: + 01:00:00

☒ Keep Interval References  
☒ Keep Interval Ref. for Delays  
☐ Keep Interval Ref. for Conn.  
☒ Update Courses / Services

Create 1 Courses

Actual Course ID: Ubrzani Course

Ref. Course ID: Remove Show

Train: EuroCity

Train Speedtype: Putnicki

Train Category: Category 1

☒ Show Operations ☒ Show Day ☒ Show Use Departure Time  
☒ Show Stationnames ☒ Show act. Data Adjust ☒ Show Delta Load  
☐ Show Stops only ☒ Show Delay Colors ☒ Show Distribution Name  
☒ Show Track Name ☒ Show Mean Delay

Delete Sync. Update Save DB Add Move Start Sort Show All Show

**Slika 27.** Vremena vožnje kod poštivanja rješenja sustava podrške za ubrzani i prigradski vlak

Iz prikazanog primjera moguće je zaključiti da primjenom rješenja sustava podrške u kombinaciji sa smanjenjem vremena zadržavanja vlakova u kolodvoru može doći do smanjenja kašnjenja prigradskog vlaka. Zbog toga taj vlak ima manji negativan utjecaj na daljnje nesmetano odvijanje prometa te ima manji potencijal da uzrokuje kašnjenje drugih vlakova. Također smanjenjem kašnjenja prigradskog vlaka dolazi do većeg zadovoljstva putnika pruženom prijevoznom uslugom, što je pozitivan učinak pogotovo zbog jako velike popunjenosti navedenog vlaka. Ubrzani vlak, ako mu se ne smanji vrijeme zadržavanja u prikazanom kolodvoru, primjenom rješenja sustava podrške može dobiti određeno kašnjenje. Navedeni vlak, pri optimalnom upravljanju prometom, ima mogućnost nadoknaditi te smanjiti kašnjenje u daljnjem prometovanju, zbog postojanja tolerancija u voznom redu te vremenu zadržavanja vlaka na stajalištima odnosno kolodvorima.

## 5.2. Drugi primjer analize rada sustava podrške pri regulaciji željezničkog prometa

Za drugi primjer uzeti su prigradski vlak te međunarodni teretni vlak. Prigradski vlak nema kašnjenja, ima popunjenost od 30 posto, te male do umjerene gubitke vremena i energije, ako treba stati na ulaznom signalu zbog davanja prednosti drugom vlaku. Međunarodni teretni vlak ima kašnjenje od 4 minute, te vrlo velike gubitke vremena i energije, ako se da prednost drugom vlaku. Nakon unošenja parametara vlakova u program Matlab, prigradski vlak dobio je 35,6 bodova, dok je međunarodni teretni vlak dobio 64,7 bodova. Na temelju toga je zaključeno da međunarodni teretni vlak ima prednost prolaska.

Za analizu rada sustava u navedenom primjeru uzete su dvije opcije u kojima se poštuje i ne poštuje rješenje sustava podrške. Usporedbom te dvije opcije vidljiv je utjecaj koji rješenja sustava podrške imaju na odvijanje prometa.

Na Slici 28. vidljiva su vozna vremena za opciju upravljanja prometom u kojoj se ne provodi rješenje sustava podrške. Vidljivo je da teretni vlak zbog potrebe za zaustavljanjem ispred ulaznog signala povećava kašnjenje te ono na kraju promatranog dijela pruge iznosi 6 minuta i 30 sekundi.

\* Timetable

Course ID	Station	Track	Arrival	Departure	Use	Dwell	Stop	Delta Load	D
Prigradski	Stanica 1			00:07:25					
Prigradski	Kolodvor		00:10:54	00:12:54	✓	120	✓	0.000	
Prigradski	Stanica 2		HH:MM:SS	00:15:50	✓	0	✗	0.000	
Teretni	Stanica 2		HH:MM:SS	00:02:36	✓	0	✗	0.000	
Teretni	Kolodvor		00:07:00	00:16:32	✓	180	✓	0.000	
Teretni	Stanica 1		HH:MM:SS	00:16:22	✓	0	✗	0.000	

Add Rows Ins. Rows Del. Rows Function: Add Stops Dwell [s]: 60 Go

Course ID	Station	Type	Min. Wait	Max. Wait	Join	Split
-----------	---------	------	-----------	-----------	------	-------

Show Conn. Course Ins. Connection Del. Connection Show all Connections

Interval 2 Courses 6 Entries

Course ID: +2 Delta Time: 01:00:00

☒ Keep Interval References  
☒ Keep Interval Ref. for Delays  
☐ Keep Interval Ref. for Conn.  
☒ Update Courses / Services

Create 1 Courses

Actual Course ID: Prigradski

Ref. Course ID:  Remove Show

Train: Prigradski

Train Speedtype: Putnicki

Train Category: Category 2

☒ Show Operations  
☒ Show Stationnames  
☐ Show Stops only  
☒ Show Track Name

☒ Show Day  
☒ Show act. Data  
☒ Show Delay Colors

☒ Show Use Departure Time  
☒ Show Delta Load  
☒ Show Distribution Name  
☒ Show Mean Delay

Adjust

Delete Sync. Update Save DB Add Move Start Sort Show All Show

**Slika 28.** Vremena vožnje kod nepoštivanja rješenja sustava podrške za prigradski i međunarodni teretni vlak

Na Slici 29. vidljiva su vozna vremena za opciju upravljanja prometom u kojoj se provodi rješenje sustava podrške. Vidljivo je da teretni vlak u kolodvoru zadržava kašnjenje od 4 minute te ne akumulira dodatno kašnjenje. Prigradski vlak zbog smanjenja vremena zadržavanja u kolodvoru ne dobiva značajnije kašnjenje.

Timetable

Course ID	Station	Track	Arrival		Departure		Use	Dwell	Stop	Delta Load	D
Prigradski	Stanica 1		HH:MM:SS		00:07:25		✓	0	•	0.000	
Prigradski	Kolodvor		00:10:54	00:12:40	00:12:54	00:13:10	✓	30	✓	0.000	
Prigradski	Stanica 2		HH:MM:SS	HH:MM:SS	00:15:50	00:16:10	✓	0	•	0.000	
Teretni	Stanica 2		HH:MM:SS	HH:MM:SS	00:02:36	00:06:36	✓	0	•	0.000	
Teretni	Kolodvor		00:07:00	00:11:00	00:10:00	00:14:00	✓	180	✓	0.000	
Teretni	Stanica 1		HH:MM:SS	HH:MM:SS	00:16:22	00:20:22	✓	0	•	0.000	

Add Rows Ins. Rows Del. Rows Function: Add Stops Dwell [s]: 60 Go

Course ID	Station	Type	Min. Wait	Max. Wait	Join	Split
-----------	---------	------	-----------	-----------	------	-------

Show Conn. Course Ins. Connection Del. Connection Show all Connections

Interval 2 Courses 6 Entries

Course ID: +2 Delta Time: + 01:00:00

☒ Keep Interval References  
☒ Keep Interval Ref. for Delays  
☐ Keep Interval Ref. for Conn.  
☒ Update Courses / Services

Create 1 Courses

Actual Course ID: Prigradski  
 Ref. Course ID:  Remove Show  
 Train: Prigradski  
 Train Speedtype: Putnicki  
 Train Category: Category 2

☒ Show Operations ☒ Show Day ☒ Show Use Departure Time  
☒ Show Stationnames ☒ Show act. Data Adjust ☒ Show Delta Load  
☐ Show Stops only ☒ Show Delay Colors ☒ Show Distribution Name  
☒ Show Track Name ☒ Show Mean Delay

Delete Sync. Update Save DB Add Move Start Sort Show All Show

**Slika 29.** Vremena vožnje kod poštivanja rješenja sustava podrške za prigradski i međunarodni teretni vlak

Primjenom rješenja sustava podrške moguće je riješiti problem dodatnog povećanja kašnjenje teretnog vlaka. Ako prometna situacija dopušta, teretnom vlaku moguće je umanjiti kašnjenje smanjenjem vremena zadržavanja vlaka u kolodvoru, što je vidljivo u Prilogu 7. Osim toga, iz Priloga 8 i 9 moguće je zaključiti da provođenje rješenja sustava podrške dovodi do smanjenja potrošnje energije međunarodnog teretnog vlaka. Do smanjenja potrošnje energije dolazi zbog toga što nije došlo do potrebe zaustavljanja i ponovnog pokretanja teretnog vlaka ispred ulaznog signala. Zbog velike potrošnje energije prilikom pokretanja teških teretnih vlakova, ako se uklone nepotrebna zaustavljanja i ponovna pokretanja može doći do smanjenja potrošnje energije i izbjegavanja njihovog dodatnog kašnjenja.

## 6. ZAKLJUČAK

U radu je objašnjen proces zaključivanja neizrazitog sustava, kao i temeljne zakonitosti koje se primjenjuju prilikom tog zaključivanja. Navedene su vrste neizrazitih sustava te njihove prednosti i nedostaci. Također su navedene mogućnosti primjene takvih sustava u procesu upravljanja željezničkim prometom. U tom procesu neizraziti sustav ima mogućnost pružanja podrške pri donošenju upravljačkih odluka koje mogu utjecati na nesmetano odvijanje željezničkog prometa.

U radu je prikazan novi model sustava podrške pri odlučivanju u procesu regulacije željezničkog prometa te postupak izrade navedenog sustava u programu Matlab. Model tog sustava podrške pruža rješenja vezana uz davanje prioriteta vlakovima u situacijama u kojim dva vlaka istovremeno žele koristiti isti dio željezničke infrastrukture. Analiza utjecaja primjene rješenja navedenog modela sustava podrške u stvarnim prometnim situacijama izvršena je u programu OpenTrack, u kojem su simulirane različite prometne situacije.

Analizom rada modela sustava podrške zaključeno je da primjena rješenja tog sustava ima pozitivan utjecaj na proces odvijanja željezničkog prometa. Pružanjem podrške dispečeru, navedeni sustav može dovesti do značajnijeg smanjenja njegovog radnog opterećenja. To utječe na povećanje učinkovitosti dispečera prilikom izvršavanja zadataka vezanih uz proces upravljanja željezničkim prometom, što može dovesti do povećanja učinkovitosti tog procesa.



## 7. LITERATURA

- [1] Haramina, H.: Inteligentni transportni sustavi u željezničkom prometu, autorizirana predavanja, Fakultet prometnih znanosti, 2017.
- [2] <http://intelligence.worldofcomputing.net/ai-introduction/artificial-intelligence-overview.html#.WxE-tExuJPY>, pristupljeno 17 lipnja 2018
- [3] <https://www.mathworks.com/help/fuzzy/what-is-fuzzy-logic.html?w.mathworks.com>, pristupljeno 18 lipnja 2018.
- [4] [https://www.tutorialspoint.com/artificial\\_intelligence/artificial\\_intelligence\\_fuzzy\\_logic\\_systems.htm](https://www.tutorialspoint.com/artificial_intelligence/artificial_intelligence_fuzzy_logic_systems.htm), pristupljeno 18 lipnja 2018.
- [5] [https://www.mathworks.com/help/fuzzy/types-of-fuzzy-inference-systems.html#bu\\_nr46-1](https://www.mathworks.com/help/fuzzy/types-of-fuzzy-inference-systems.html#bu_nr46-1), pristupljeno 19 lipnja 2018.
- [6] <https://ch.mathworks.com/help/fuzzy/what-is-sugeno-type-fuzzy-inference.html>, pristupljeno 19 lipnja 2018.
- [7] <https://www.mathworks.com/help/fuzzy/comparison-of-sugeno-and-mamdani-systems.html>, pristupljeno 21 lipnja 2018.
- [8] <https://www.mathworks.com/help/fuzzy/foundations-of-fuzzy-logic.html#bp78l70-2>, pristupljeno 25 lipnja 2018.
- [9] <https://www.mathworks.com/help/fuzzy/fuzzy-inference-process.html>, pristupljeno 25 lipnja 2018.
- [10] Takashige T.: Signalling Systems for Safe Railway Transport, Railway Tehnology Today 8, Japan, 1999.
- [11] Frank W. Bryan: CTC: Remotely directing the movement of trains, Trains magazine, 2006.
- [12] <https://mysite.du.edu/~jcalvert/railway/ctc.htm>, pristupljeno 14 srpnja 2018.
- [13] Središnje upravljanje prometom-telekomanda, studija, Željezničko projektno društvo, Zagreb
- [14] Kauppi A.: A Human-Computer Interaction Approach to Train Traffic Control, Uppsala University, Švedska, 2006.

- [15] C. A. Brebbia, N. Tomii, P. Tzieropoulos, J. M. Mera: Railway track layout modelling and its application to an automatic route setting, Computers in Railways XIV, Japan, 2014.
- [16] Haramina, H., Sumpor, D., Širol M.: Modelling of Fuzzy Logic Based Dispatcher Support System for Railway Traffic Control, Book of Proceedings of the 7<sup>th</sup> International Ergonomics Conference, Croatian Ergonomics Society, Zagreb, 2018.

## POPIS SLIKA

<b>Slika 1.</b> Pojednostavljeni prikaz glavnih procesa sustava neizrazitog zaključivanja ...	6
<b>Slika 2.</b> Pridjeljivanje vrijednosti pripadnosti klasičnom i neizrazitom logičkom skupu	8
<b>Slika 3.</b> Logički skupovi u programu Matlab .....	8
<b>Slika 4.</b> Funkcija pripadnosti neizrazitom logičkom skupu visokih ljudi .....	9
<b>Slika 5.</b> Linearne funkcije pripadnosti.....	10
<b>Slika 6.</b> Primjena neizrazitih logičkih operatora.....	12
<b>Slika 7.</b> Primjer IF-THEN pravila .....	14
<b>Slika 8.</b> Postupci procesa zaključivanja u neizrazitom logičkom sustavu .....	16
<b>Slika 9.</b> Prikaz sučelja u centru za dispečersko upravljanje željezničkim prometom	20
<b>Slika 10.</b> Prikaz položaja vlakova na dijelu pruge s centraliziranim upravljanjem ....	23
<b>Slika 11.</b> Primjeri putova vožnje vlaka kod automatskog postavljanja putova vožnje	27
<b>Slika 12.</b> Virtualna rezervacija putova vožnje .....	29
<b>Slika 13.</b> Primjer suprotstavljenih putova vožnje .....	31
<b>Slika 14.</b> Definiranje ulaznih i izlaznih varijabli sustava podrške pri regulaciji željezničkog prometa .....	34
<b>Slika 15.</b> Ulazna varijabla: Razlika u rangu vlaka.....	35
<b>Slika 16.</b> Ulazna varijabla: Kašnjenje vlaka koje utječe na stabilnost drugih vlakova	36
<b>Slika 17.</b> Ulazna varijabla: Popunjenost putničkog vlaka .....	37
<b>Slika 18.</b> Ulazna varijabla: Gubici vremena i energije zbog zaustavljanja vlaka.....	38
<b>Slika 19.</b> Izlazna varijabla: Broj bodova .....	39
<b>Slika 20.</b> Definiranje pravila.....	40
<b>Slika 21.</b> Prozor za provjeru definiranih pravila .....	41
<b>Slika 22.</b> Prikaz površine međuovisnosti ulaznih i izlaznih varijabli sustava .....	42
<b>Slika 23.</b> Broj bodova za ubrzani vlak u primjeru primjene modela sustava podrške	43

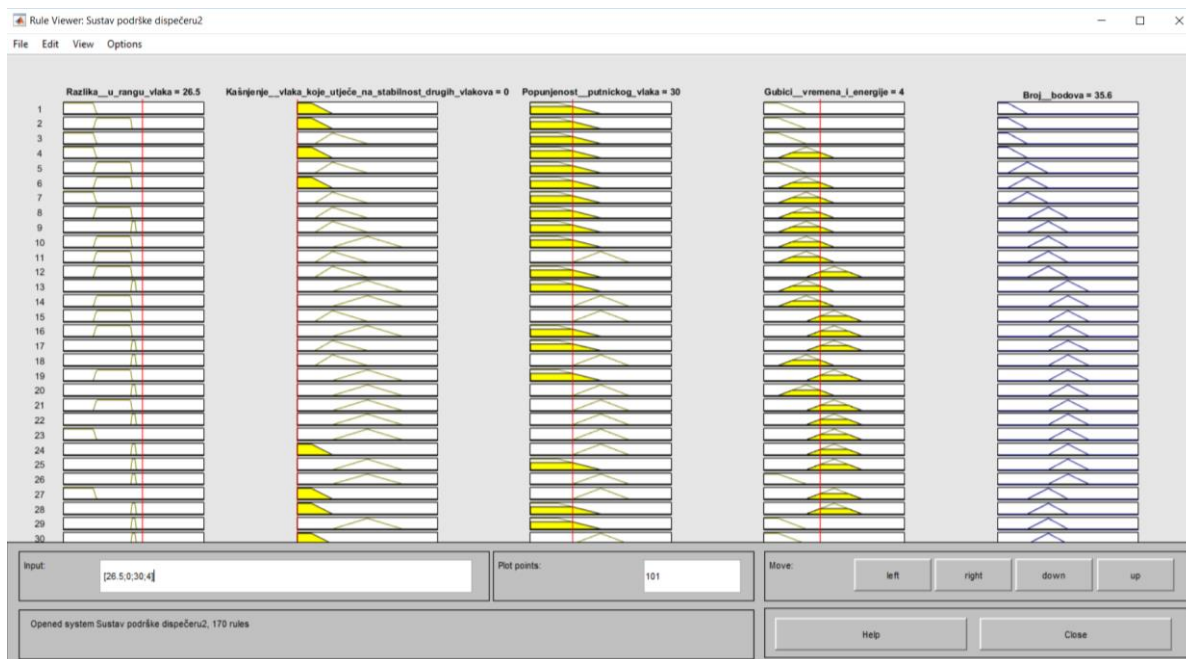
<b>Slika 24.</b> Broj bodova za prigradski vlak u primjeru primjene modela sustava podrške .....	44
<b>Slika 25.</b> Model za analizu sustava podrške u programu OpenTrack .....	46
<b>Slika 26.</b> Vremena vožnje kod nepoštivanja rješenja sustava podrške za ubrzani i prigradski vlak.....	47
<b>Slika 27.</b> Vremena vožnje kod poštivanja rješenja sustava podrške za ubrzani i prigradski vlak.....	48
<b>Slika 28.</b> Vremena vožnje kod nepoštivanja rješenja sustava podrške za prigradski i međunarodni teretni vlak .....	49
<b>Slika 29.</b> Vremena vožnje kod poštivanja rješenja sustava podrške za prigradski i međunarodni teretni vlak .....	50

## POPIS TABLICA

<b>Tablica 1.</b> Klasični logički operatori.....	11
<b>Tablica 2.</b> Neizraziti logički operatori .....	12

## PRILOZI

- Prilog 1. Ostvareni broj bodova ubrzanog vlaka u prvom primjeru analize rada sustava podrške pri regulaciji željezničkog prometa



- Prilog 2. Ostvareni broj bodova prigradskog vlaka u prvom primjeru analize rada sustava podrške pri regulaciji željezničkog prometa



Prilog 3. Vremena vožnje kod nepoštivanja rješenja sustava podrške za ubrzani i prigradski vlak ukoliko se smanji vrijeme zadržavanja prigradskog vlaka u kolodoru

Timetable

Course ID	Station	Track	Arrival	Departure	Use	Dwell	Stop	Delta Load	D
+ Prigradski	Stanica 2		HH:MM:SS HH:MM:SS	00:02:36 00:06:36	✓	0	-	0.000	
Prigradski	Kolodvor		00:06:05 00:11:41	00:08:05 00:12:11	✓	30	✓	0.000	
+ Prigradski	Stanica 1		HH:MM:SS HH:MM:SS	00:11:01 00:15:11	✓	0	-	0.000	
+ Ubrzani	Stanica 1		HH:MM:SS	00:06:36	✓	0	-	0.000	
Ubrzani	Kolodvor		00:10:05 00:10:01	00:12:05 00:12:05	✓	120	✓	0.000	
Ubrzani	Stanica 2		HH:MM:SS HH:MM:SS	00:15:01 00:15:01	✓	0	-	0.000	

Add Rows Ins. Rows Del. Rows Function: Add Stops Dwell [s]: 60 Go

Course ID	Station	Type	Min. Wait	Max. Wait	Join	Split
-----------	---------	------	-----------	-----------	------	-------

Show Conn. Course Ins. Connection Del. Connection Show all Connections

Interval Course ID: +2 Delta Time: 01:00:00

☒ Keep Interval References  
☒ Keep Interval Ref. for Delays  
☐ Keep Interval Ref. for Conn.  
☒ Update Courses / Services

Create 1 Courses

Actual Course ID: Ubrzani Course

Ref. Course ID: Remove Show

Train: EuroCity  
Train Speedtype: Putnicki  
Train Category: Category 1

☒ Show Operations  
☒ Show Stationnames  
☐ Show Stops only  
☒ Show Track Name

☒ Show Day  
☒ Show act. Data Adjust  
☒ Show Delay Colors

☒ Show Use Departure Time  
☒ Show Delta Load  
☒ Show Distribution Name  
☒ Show Mean Delay

Delete Sync. Update Save DB Add Move Start Sort Show All Show

Prilog 4. Vremena vožnje kod poštivanja rješenja sustava podrške za ubrzani i prigradski vlak ukoliko se ne smanjuje vrijeme zadržavanja vlakova u kolodvoru

Timetable

Course ID	Station	Track	Arrival	Departure	Use	Dwell	Stop	Delta Load	D
+ Prigradski	Stanica 2		HH:MM:SS HH:MM:SS	00:02:36 00:06:36	✓	0	-	0.000	
Prigradski	Kolodvor		00:06:05 00:10:01	00:08:05 00:12:01	✓	120	✓	0.000	
+ Prigradski	Stanica 1		HH:MM:SS HH:MM:SS	00:11:01 00:14:57	✓	0	-	0.000	
+ Ubrzani	Stanica 1		HH:MM:SS	00:06:36	✓	0	-	0.000	
Ubrzani	Kolodvor		00:10:05 00:11:41	00:12:05 00:13:41	✓	120	✓	0.000	
+ Ubrzani	Stanica 2		HH:MM:SS HH:MM:SS	00:15:01 00:16:41	✓	0	-	0.000	

Add Rows Ins. Rows Del. Rows Function: Add Stops Dwell [s]: 60 Go

Course ID	Station	Type	Min. Wait	Max. Wait	Join	Split
-----------	---------	------	-----------	-----------	------	-------

Show Conn. Course Ins. Connection Del. Connection Show all Connections

Interval Course ID: +2 Delta Time: 01:00:00

☒ Keep Interval References  
☒ Keep Interval Ref. for Delays  
☐ Keep Interval Ref. for Conn.  
☒ Update Courses / Services

Create 1 Courses

Actual Course ID: Ubrzani Course

Ref. Course ID: Remove Show

Train: EuroCity  
Train Speedtype: Putnicki  
Train Category: Category 1

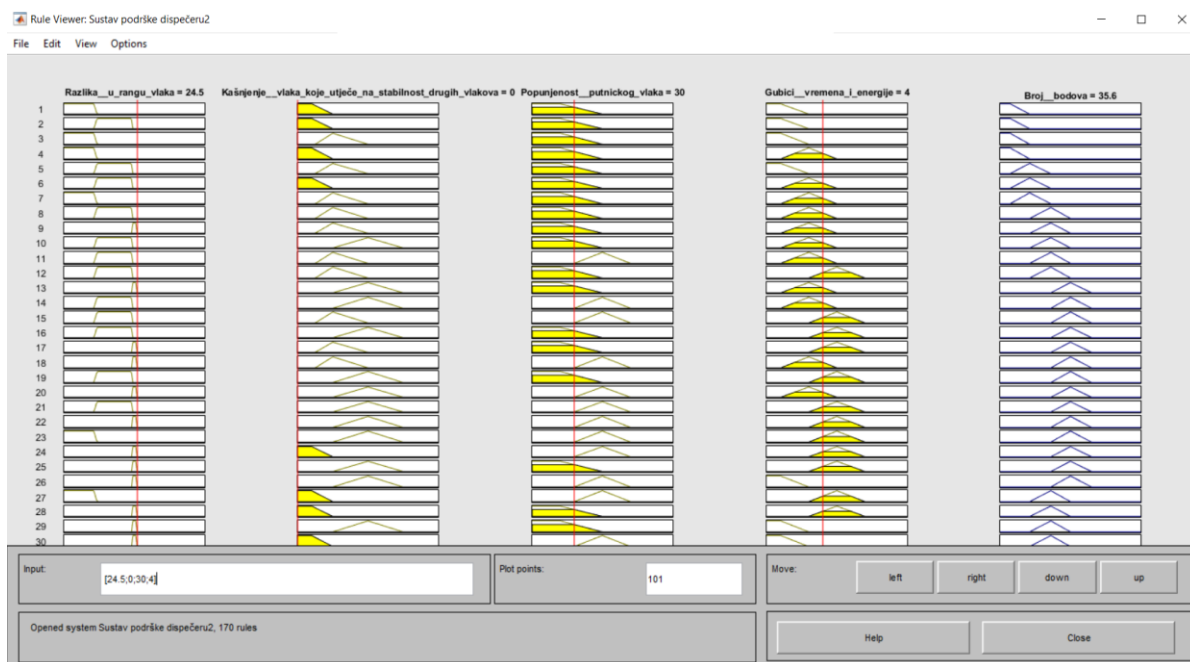
☒ Show Operations  
☒ Show Stationnames  
☐ Show Stops only  
☒ Show Track Name

☒ Show Day  
☒ Show act. Data Adjust  
☒ Show Delay Colors

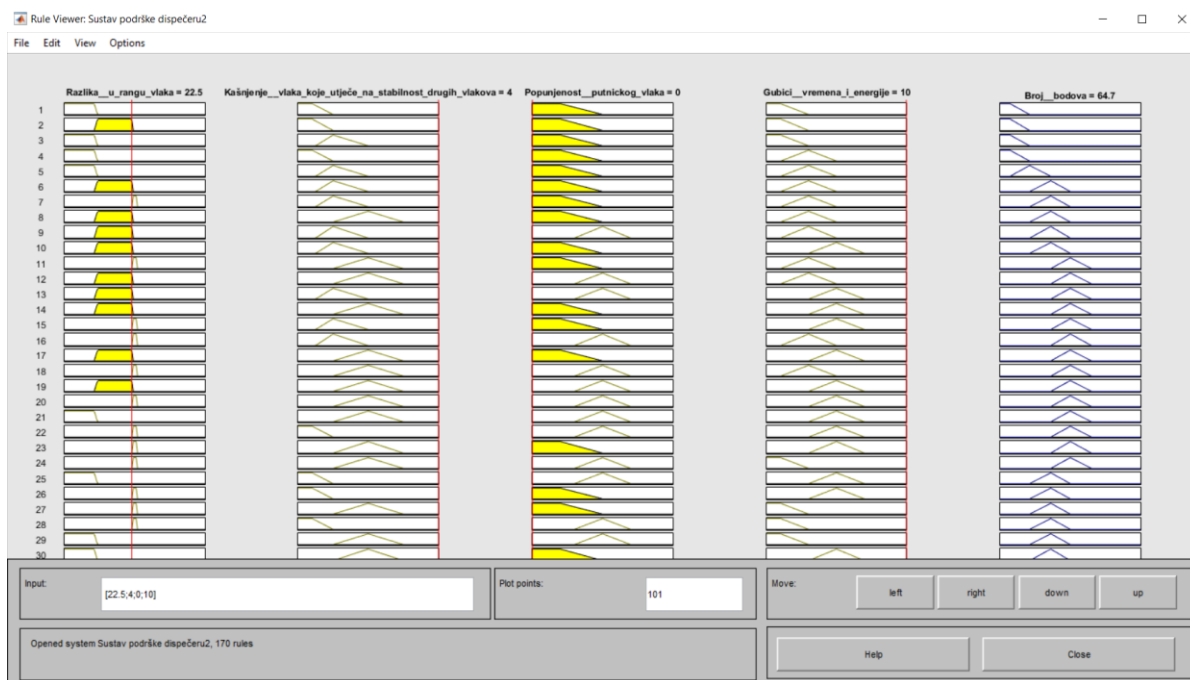
☒ Show Use Departure Time  
☒ Show Delta Load  
☒ Show Distribution Name  
☒ Show Mean Delay

Delete Sync. Update Save DB Add Move Start Sort Show All Show

Prilog 5. Ostvareni broj bodova prigradskog vlaka u drugom primjeru analize rada sustava podrške pri regulaciji željezničkog prometa



Prilog 6. Ostvareni broj bodova međunarodnog teretnog vlaka u drugom primjeru analize rada sustava podrške pri regulaciji željezničkog prometa



Prilog 7. Vremena vožnje kod poštivanja rješenja sustava podrške za prigradski i međunarodni teretni vlak ukoliko se smanjuje vrijeme zadržavanja vlakova na kolodvoru

Timetable

Course ID	Station	Track	Arrival	Departure	Use	Dwell	Stop	Delta Load	D
Prigradski	Stanica 1		HH:MM:SS	00:07:25	✓	0	•	0.000	↕
Prigradski	Kolodvor		00:10:54 00:12:40	00:12:54 00:13:10	✓	30	✓	0.000	
Prigradski	Stanica 2		HH:MM:SS HH:MM:SS	00:15:50 00:16:10	✓	0	✓	0.000	
Teretni	Stanica 2		HH:MM:SS HH:MM:SS	00:02:36 00:08:36	✓	0	✓	0.000	
Teretni	Kolodvor		00:07:00 00:11:00	00:10:00 00:12:00	✓	60	✓	0.000	
Teretni	Stanica 1		HH:MM:SS HH:MM:SS	00:16:22 00:18:22	✓	0	✓	0.000	

Add Rows Ins. Rows Del. Rows Function: Add Stops Dwell [s]: 60 Go

Course ID	Station	Type	Min. Wait	Max. Wait	Join	Split
-----------	---------	------	-----------	-----------	------	-------

Show Conn. Course Ins. Connection Del. Connection Show all Connections

Interval 2 Courses 6 Entries

Course ID: +2 Delta Time: + 01:00:00

☒ Keep Interval References  
☒ Keep Interval Ref. for Delays  
☐ Keep Interval Ref. for Conn.  
☒ Update Courses / Services


Create 1 Courses

Actual Course ID: Prigradski Course  
 Ref. Course ID: Remove Show  
 Train: Prigradski  
 Train Speedtype: Putnicki  
 Train Category: Category 2

☒ Show Operations ☒ Show Day ☒ Show Use Departure Time  
☒ Show Stationnames ☒ Show act. Data Adjust ☒ Show Delta Load  
☐ Show Stops only ☒ Show Delay Colors ☒ Show Distribution Name  
☒ Show Track Name ☒ Show Mean Delay


Delete Sync. Update Save DB Add Move Start Sort Show All Show

Prilog 8. Potrošnja energije međunarodnog teretnog vlaka pri nepoštivanju rješenja sustava podrške za drugi primjer analize rada sustava podrške pri regulaciji željezničkog prometa





Prilog 9.      Potrošnja energije međunarodnog teretnog vlaka pri poštivanju rješenja sustava podrške za drugi primjer analize rada sustava podrške pri regulaciji željezničkog prometa





Sveučilište u Zagrebu  
Fakultet prometnih znanosti  
10000 Zagreb  
Vukelićeva 4

## IZJAVA O AKADEMSKOJ ČESTITOSTI I SUGLASNOST

Izjavljujem i svojim potpisom potvrđujem kako je ovaj \_\_\_\_\_ diplomski rad  
isključivo rezultat mog vlastitog rada koji se temelji na mojim istraživanjima i oslanja se na  
objavljenu literaturu što pokazuju korištene bilješke i bibliografija.

Izjavljujem kako nijedan dio rada nije napisan na nedozvoljen način, niti je prepisan iz  
necitiranog rada, te nijedan dio rada ne krši bilo čija autorska prava.

Izjavljujem također, kako nijedan dio rada nije iskorišten za bilo koji drugi rad u bilo kojoj drugoj  
visokoškolskoj, znanstvenoj ili obrazovnoj ustanovi.

Svojim potpisom potvrđujem i dajem suglasnost za javnu objavu \_\_\_\_\_ diplomskog rada  
pod naslovom \_\_\_\_\_  
Sustav podrške pri odlučivanju u procesu regulacije željezničkog  
prometa temeljen na neizrazitoj logici  
na internetskim stranicama i repozitoriju Fakulteta prometnih znanosti, Digitalnom  
akademsom

repozitoriju (DAR) pri Nacionalnoj i sveučilišnoj knjižnici u Zagrebu.

Student/ica:

U Zagrebu, \_\_\_\_\_ 12. rujna 2018. \_\_\_\_\_

\_\_\_\_\_  
(potpis)